




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA STAVEBNÍ

ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

FACULTY OF CIVIL ENGINEERING INSTITUTE OF LANDSCAPE WATER  
MANAGEMENT

# MODELOVÁNÍ POVODŇOVÝCH VLN V HORNÍ ČÁSTI POVODÍ ŘEKY JIHLAVY

EVALUATION OF FLOOD WAVES IN THE UPPER PART OF JIHLAVA RIVER BASIN

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

*AUTOR PRÁCE*

AUTHOR

*BC. TOMÁŠ KOZEL*

*VEDOUCÍ PRÁCE*

SUPERVISOR

*prof. Ing. MILOŠ STARÝ, CSc.*

BRNO 2014



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

<b>Studijní program</b>	N3607 Stavební inženýrství
<b>Typ studijního programu</b>	Navazující magisterský studijní program s prezenční formou studia
<b>Studijní obor</b>	3607T027 Vodní hospodářství a vodní stavby
<b>Pracoviště</b>	Ústav vodního hospodářství krajiny

## ZADÁNÍ DIPLOMOVÉ PRÁCE

<b>Diplomant</b>	Bc. Tomáš Kozel
<b>Název</b>	Modelování povodňových vln v horní části povodí řeky Jihlavy
<b>Vedoucí diplomové práce</b>	prof. Ing. Miloš Starý, CSc.
<b>Datum diplomové práce</b>	<b>zadání</b> 31. 3. 2013
<b>Datum diplomové práce</b>	<b>odevzdání</b> 17. 1. 2014

V Brně dne 31. 3. 2013

.....  
prof. Ing. Miloš Starý, CSc.  
Vedoucí ústavu

.....  
prof. Ing. Rostislav Drochytka, CSc., MBA  
Děkan Fakulty stavební VUT

## **ABSTRAKT**

Práce se zabývá konstrukcí předpovědních modelů určených pro předpovídání povodňových průtoků v systémech Batelov – Dvorce, Dvorce – Ptáčov a Batelov – Ptáčov na řece Jihlavě. Pro předpovídání průtoků byly použity klasické hydrologické postupy, dle kterých byly sestaveny regresní rovnice použité pro předpovídání. Mimo běžných postupů byly použity i modely vycházející z neuronových sítí. Modely byly tvořeny pro data z let 1960 – 2010. Na závěr bylo provedeno vyhodnocení. V práci byly rovněž stanoveny empirické i teoretické čáry překročení objemů povodňových vln pro jednotlivé stanice.

## **KLÍČOVÁ SLOVA**

Hydrogram, Regresní analýza, Neuronové sítě, Jihlava, Kulminační průtok

## **ABSTRACT**

This thesis is about construction of forecasting models for prediction of flood flows of systems measuring profile Batelov – Dvorce, Dvorce – Ptáčov and Batelov – Ptáčov on the river Jihlava. For forecasting flood flows were used classic hydrological forecasting models. Another forecasting models contained neural networks. Data for construction of forecasting models were used for years 1960 – 2010. Evaluation was made in the end of thesis. The thesis also contains theoretical line of flood flows volume.

## **KEYWORDS**

Hydrograph, Regression analysis, Neural network, Jihlava, Peak flow

## **BIBLIOGRAFICKÁ CITACE VŠKP**

Bc. Tomáš Kozel *Modelování povodňových vln v horní části povodí řeky Jihlavy*. Brno, 2014. 85 s., 50 s. příl. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce prof. Ing. Miloš Starý, CSc..



**Prohlášení:**

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje.

V Brně dne 15.1.2014

.....  
podpis autora  
Bc. Tomáš Kozel

## **PODĚKOVÁNÍ**

Rád bych poděkoval svému vedoucímu bakalářské práce prof. Ing. Miloši Starému, CSc. za veškerou pomoc při zpracovávání této bakalářské práce. Také bych chtěl poděkovat pracovníkům Českého hydrometeorologického ústavu v Brně za jejich pomoc, ochotu a poskytnutí dat potřebných pro tuto práci. Jmenovitě paní Ing. Evě Soukalové, CSc a panu Mgr. Stanislavu Lejskovi.

## Obsah

<b>1</b>	<b>ÚDAJE O POVODÍ .....</b>	<b>11</b>
<b>2</b>	<b>ÚDAJE O VODOMĚRNÝCH STANICÍCH .....</b>	<b>12</b>
<b>2.1</b>	<b>Batelov.....</b>	<b>13</b>
2.1.1	Základní údaje: .....	13
2.1.2	Popis stanice .....	13
2.1.3	Umístění stanice.....	14
<b>2.2</b>	<b>Dvorce .....</b>	<b>16</b>
2.2.1	Základní údaje: .....	16
2.2.2	Popis stanice .....	16
2.2.3	Umístění stanice.....	17
<b>2.3</b>	<b>Ptáčov.....</b>	<b>19</b>
2.3.1	Základní údaje: .....	19
2.3.2	Popis stanice .....	19
2.3.3	Umístění stanice.....	20
<b>3</b>	<b>ZPRACOVÁNÍ HISTORICKÝCH DAT .....</b>	<b>22</b>
<b>4</b>	<b>PŘEVOD VODNÍCH STAVŮ NA PRŮTOKY .....</b>	<b>23</b>
<b>4.1</b>	<b>Měrná křivka průtoků (MKP).....</b>	<b>23</b>
<b>5</b>	<b>VYHODNOCENÍ N-LETÝCH PRŮTOKŮ.....</b>	<b>25</b>
<b>5.1</b>	<b>Zpracování dat.....</b>	<b>25</b>
<b>5.2</b>	<b>Sestavení čáry překročení pro objemy povodní .....</b>	<b>25</b>
<b>6</b>	<b>URČENÍ POSTUPOVÉ DOBY POVODŇOVÝCH PRŮTOKŮ .....</b>	<b>27</b>
<b>6.1</b>	<b>Určení postupové doby průtoku .....</b>	<b>27</b>
<b>6.2</b>	<b>Křivky postupových dob průtoků.....</b>	<b>27</b>
<b>6.3</b>	<b>Metoda vzájemně si odpovídajících průtoků .....</b>	<b>32</b>
<b>7</b>	<b>REGRESNÍ ANALÝZA .....</b>	<b>33</b>
<b>7.1</b>	<b>Postup při prokládání regresní křivky Shlukem bodů[2] .....</b>	<b>35</b>
<b>7.2</b>	<b>Sestavení regresního modelu.....</b>	<b>36</b>
<b>8</b>	<b>MODEL VYUŽÍVAJÍCÍ NEURONOVÉ SÍŤ.....</b>	<b>48</b>
<b>8.1</b>	<b>Umělé Neuronové síť .....</b>	<b>48</b>
8.1.1	Základní pojmy .....	48
8.1.2	Přenosové funkce.....	50

8.1.3	Metody trénování.....	51
8.1.4	Způsob trénování .....	51
<b>8.2</b>	<b>Postup vytváření předpovědního modelu obsahujícího neuronové sítě .....</b>	<b>52</b>
8.2.1	Obecný popis neuronové sítě v modelech.....	52
8.2.2	Modely varianta 1 .....	54
8.2.3	Modely varianta 1.1 .....	55
<b>8.3</b>	<b>Model Batelov- Dvorce .....</b>	<b>56</b>
8.3.1	Kritéria úspěšnosti modelu .....	56
8.3.2	Hodnocení úspěšnosti modelu .....	57
<b>8.4</b>	<b>Model Dvorce – Ptáčov .....</b>	<b>60</b>
8.4.1	Kritéria úspěšnosti modelu .....	60
8.4.2	Hodnocení úspěšnosti modelu .....	60
<b>8.5</b>	<b>Model Batelov – Ptáčov .....</b>	<b>64</b>
8.5.1	Kritéria úspěšnosti modelu .....	64
8.5.2	Hodnocení úspěšnosti modelu .....	64
8.5.3	Srovnání modelu Dvorce – Ptáčov a Batelov – Ptáčov.....	67
<b>8.6</b>	<b>Modely s neuronovou sítí 2.0.....</b>	<b>69</b>
<b>9</b>	<b>ANALÝZA VÝSLEDKŮ A SROVNÁNÍ VÝSLEDKŮ.....</b>	<b>71</b>
9.1	Rozhodovací tabulka pro regresní vztahy .....	76
<b>10</b>	<b>ZÁVĚR .....</b>	<b>77</b>
<b>11</b>	<b>POUŽITÁ LITERATURA.....</b>	<b>79</b>
<b>12</b>	<b>SEZNAM OBRÁZKŮ .....</b>	<b>80</b>
<b>13</b>	<b>SEZNAM TABULEK .....</b>	<b>83</b>
<b>14</b>	<b>SEZNAM PŘÍLOH.....</b>	<b>83</b>
Příloha 1 – Hydrogramy Povodní Pro Model 1.2 a Závislosti B-D.....		83
Příloha 2 – Ukázka M – file pro model 1.2.....		83
Příloha 3 – teoretické a empirické čáry překročení .....		83
<b>15</b>	<b>SEZNAM ZKRATEK A ZNAČEK .....</b>	<b>84</b>
<b>PŘÍLOHA 1 .....</b>		<b>85</b>
<b>PŘÍLOHA 2 .....</b>		<b>113</b>
M – file .....		114
<b>PŘÍLOHA 3 .....</b>		<b>130</b>

<b>Měrný profil Batelov.....</b>	<b>131</b>
<b>Měrný profil Dvorce .....</b>	<b>132</b>
<b>Měrný profil Ptáčov .....</b>	<b>133</b>

# ÚVOD

V současné době narůstá počet výskytů extrémních jevů, jako jsou sucha a nadměrné srážky. Z extrémních srážek a z tání sněhové pokrývky velmi často vznikají povodňové události, a proto je zapotřebí tvořit protipovodňová opatření, která slouží ke zmírnění jejich dopadů. K protipovodňovým opatřením patří i operativní řízení odtoku z nádrží za průchodu povodní. Pro řízení je velkou výhodou znát hodnoty průtoků s určitým předstihem. K tomuto účelu slouží předpovědní modely, které jsou schopny s předstihem předpovídat průtoky v profilech níže položených po toku na základě průtoků v profilech výše položených po toku.

## CÍL PRÁCE

Cílem práce je sestavení modelů pro předpověď povodňových průtoků pro dvojice měrných profilů Batelov – Dvorce, Dvorce – Ptáčov, Batelov – Ptáčov na řece Jihlavě. Modely budou sestaveny na základě historických pozorování vodních stavů. V práci budou použity programy Microsoft Excel, Matlab R2010a a RCPNV.

První předpovědní modely budou vytvořeny za pomoci regresní analýzy metodou odpovídajících si průtoků. Pro každý model bude vytvořeno několik variant, aby byla vybrána ta nejlepší varianta. Pokud se objeví povodňová událost, kterou nebude schopen žádný ze standardních modelů předpovědět a její N-letost bude vyšší jak 5, bude pro ni sestaven zvláštní model. Na konci práce bude uvedena rozhodovací tabulka, která bude obsahovat nejlepší regresní vztahy.

Druhým způsobem tvorby předpovědních modelů bude vytváření modelů obsahující neuronové sítě. Pro tvorbu modelů bude použit Neural toolbox programu Matlab R2010a. Pro každý model bude sestaveno několik variant a nakonec bude vybrána ta nejlepší.

Posledním krokem u tvorby modelů bude doporučení pro výběr vhodného modelu pro předpověď průtoků.

Dále bude sestavena teoretická čára překročení objemů a zapsání vybraných hodnot do tabulky pro každý měrný profil.

Práce pracovala s daty z let 1960 – 2010, která byla převzata z bakalářské práce.

# 1 ÚDAJE O POVODÍ

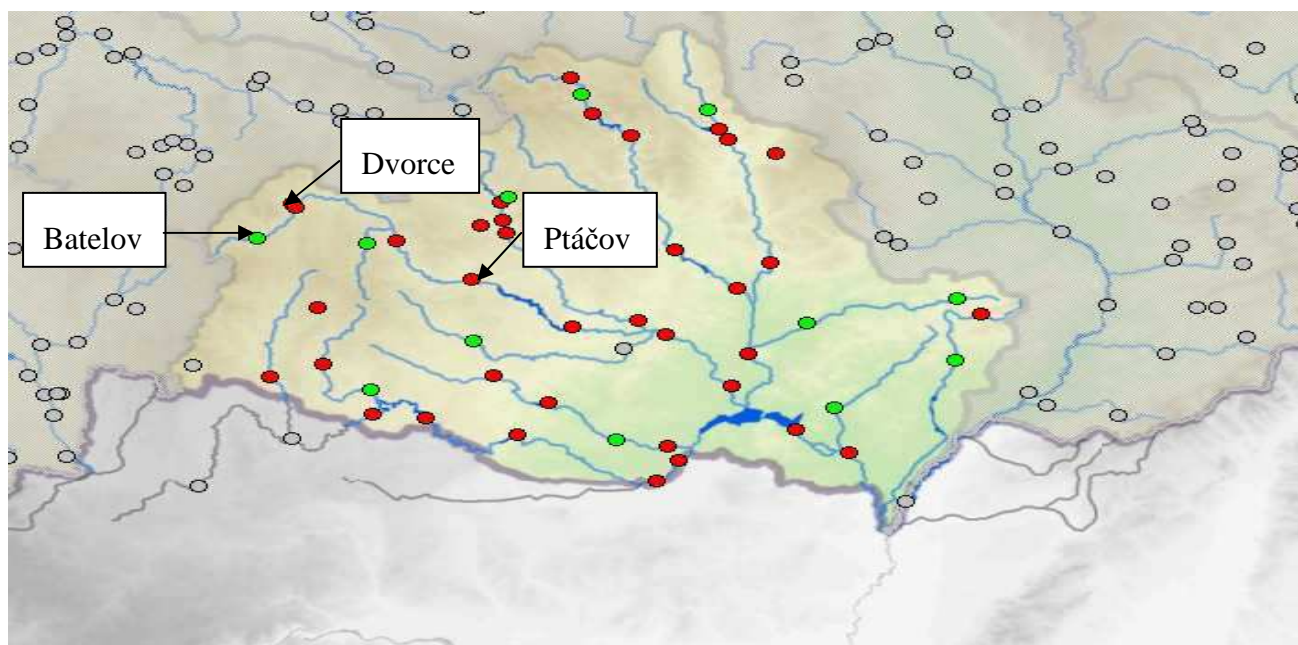
Jihlava patří mezi významné toky naší republiky. Pramení u obce Jihlávka (680 m n. m.), která náleží ke kraji Vysočina. Na Moravě ústí do řeky Svatky (povodí Dunaje) těsně před Novomlýnskými nádržemi. Délka toku činí 184.5 km. Plocha povodí činí 3117 km<sup>2</sup>. Povodí leží v oblasti podnebí MT1 a MT2. Větší část náleží typu MT1. To znamená, že se jedná o mírně teplé, suché podnebí, s roční sumou teplot nad +10 °C, která nabývá hodnot 2400 až 2600, s průměrnou roční teplotou 7- 8,5 °C. Průměrný roční úhrn srážek činí do 450 až 550 mm a počet letních dnů v roce 20 – 30. Na jejím toku se nachází vodní nádrž Dalešice a vodní nádrž Mohelno. Část toku řeky Jihlavy tvoří historické zemské hranice mezi Čechy a Moravou. Jihlava teče v hluboké (až 160 m) dolině na dolním toku. Protéká Jihlavou, Třebíčí, Pohořelicemi a vlévá se zleva do střední novomlýnské nádrže. Mezi významné přítoky patří: Třešťský potok ( zprava, ř. km 160.0), Jihlávka ( zprava, ř. km 142.6), Brtnice (zprava, ř. km 123.4), Oslava ( zleva, ř. km 39.7), Rokytná (zprava, ř. km 38.1). Jedná se o řeku vodácky využitelnou. Jezdí se úsek řeky mezi vodní nádrží Mohelno a Hrubšicemi, řeka je sjízdná pouze při vypouštění z přehrady. Za vysokého stavu vody lze jet i horní úsek řeky od Dolní Cerekve po Vladislav. Tok Jihlavy je na dvou místech uměle přehrazen[1]:

- vodní nádrž Dalešice,
- vodní nádrž Mohelno.

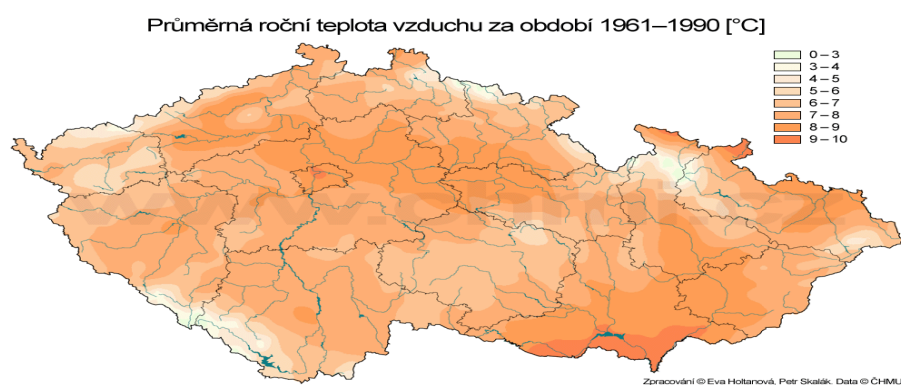
Vodní nádrže Dalešice a Mohelno tvoří zásobárnu chladicí vody pro jadernou elektrárnu Dukovany. Mezi těmito přehradami je vybudována přečerpávací vodní elektrárna Dalešice s výkonem 4x120 MW [1].

## 2 ÚDAJE O VODOMĚRNÝCH STANICÍCH

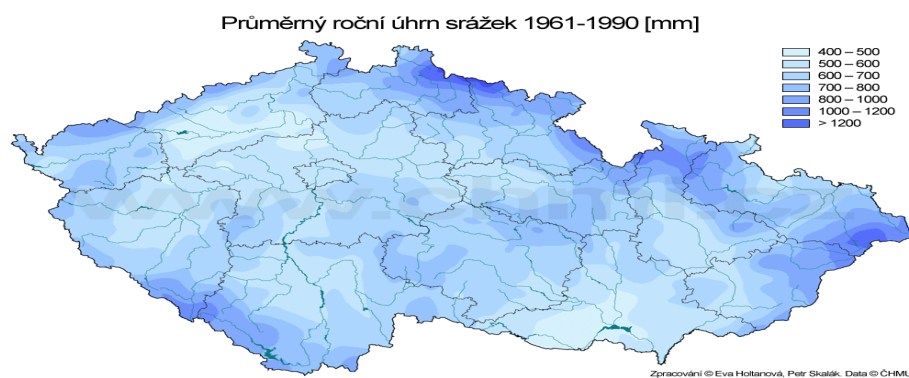
Legenda: ● Hlásné profily kategorie A ● Hlásné profily kategorie B



Obr. 1. Měrné profily



Obr. 2. Průměrná roční teplota



Obr. 3. Průměrný srážkový úhrn



## 2.1 BATELOV

### 2.1.1 Základní údaje:

Název stanice:	BATELOV
Tok:	Jihlava
Hydrologické číslo:	4-16-01-009
Číslo databanky:	4630
Staničení [km]:	169.4
Plocha povodí [km <sup>2</sup> ]:	73.45
Dlouhodobý průměrný průtok $Q_a$ :	0.600 [m <sup>3</sup> /s]
Dlouhodobý průměrný roční stav:	54.00 [cm]

**Tab. 1.** *Geografické údaje o vodoměrné stanici Batelov*

Zeměpisné souřadnice		
zem. délka	zem. šířka	Břeh
152429	491851	P

**Tab. 2.** *N-leté průtoky Batelov ( $Q_N$  - m<sup>3</sup>/s)*

Roky	1	2	5	10	20	50	100
Q [m <sup>3</sup> /s]	4.00	6.00	9.00	12.0	14.50	19.00	23.00

### 2.1.2 Popis stanice

Jedná se o zděnou budovu, která má půdorysné rozměry 2.5 x 2.5 m a výšku 2.3 m bez střechy. Střecha je stanového typu a jako krytina je použita pálená taška. Stanice je umístěna na betonovém soklu. Ke stanici vede chodníček a přístup k toku je řešen schůdky. Jedná se o novou měrnou stanici, která nahradila starou v roce 2002.[6]

**Šachta:** průměr: 600 mm hloubka: 2500 mm

**Přívodní kanál:** průměr: 150 mm hloubka: 3500 mm

**Vodočet:** nadmořská výška nuly 540.86 B.v.p.

- šikmý: plech na dřevu, délka 2200 mm, E: 100 mm, rozpětí 0 – 2100 mm
- svislý: plech na dřevu, délka 1100 mm, E: 100 mm, rozpětí 2100 – 3100 mm

#### **Přístrojové vybavení stanice:**

1952 – 2002 přístroj: limnigraf

2002 – dosud přístroj: NOEL – aut. záznam.


**Dno:** přirozené kamenité

**Ovlivnění:** v zimě dochází k ledovým jevům


**Břehy:** Pravý břeh je přirozený. Jen pod stanicí a kolem ní je vybudováno opevnění z kamene do betonu. Levý břeh je tvořen opěrnou stěnou, která je postavena z kamene. Parkoviště patří továrně Motorpal. Dále pod továrnou je břeh přirozený. [6]

### **2.1.3 Umístění stanice**

Stanice se nachází na pravém břehu v Batelově. Ke stanici se dá přijet po komunikaci, která vede k továrně Motorpal a k místní ČOV. Na tuto cestu se dostaneme odbočením doleva z komunikace 402 ze směru na Třešť. Stanice se nachází 30 m nad silničním mostkem. Pro lepší orientaci viz obr. 2 pod textem[6]



**Obr. 4.** Umístění měrného profilu



**Obr. 5.** Příčný profil měrného profilu Batelov



**Obr. 6.** Foto stanice a měrného profilu Batelov

## 2.2 DVORCE

### 2.2.1 Základní údaje:

Název stanice:	DVORCE
Tok:	Jihlava
Hydrologické číslo:	4-16-01-027
Číslo databanky:	4650
Staničení [km]:	155.8
Plocha povodí [km <sup>2</sup> ]:	307.69
Dlouhodobý průměrný průtok $Q_a$ :	1.980 [m <sup>3</sup> /s]
Dlouhodobý průměrný roční stav:	45.00 [cm]

Tab. 3. Geografické údaje o vodoměrné stanici Dvorce

Zeměpisné souřadnice		
zem. délka	zem. šířka	Břeh
153015	492257	P

Tab. 4.  $N$ -leté průtoky Dvorce ( $Q_N$  - m<sup>3</sup>/s)

Roky	1	2	5	10	20	50	100
$Q$ [m <sup>3</sup> /s]	16.00	22.00	30.00	37.00	44.00	54.00	62.00

### 2.2.2 Popis stanice

Jedná se o zděnou budovu, která má půdorysné rozměry 2.5 x 2.5 m a výšku 2.3 m bez střechy. Střecha je stanového typu a jako krytina je použita pálená taška. Stanice je umístěna na betonovém soklu. Ke stanici vede cesta a přístup k toku je řešen schůdky. Jedná se o novou měrnou stanici, která nahradila starou v roce 2002. [6]

**Šachta:** průměr: 600 mm hloubka: 3500 mm

**Přívodní kanál:** průměr: 150 mm hloubka: 2500 mm

**Vodočet:** nadmořská výška nuly 501,15 B.v.p.

- šikmý: plech na dřevu, délka 4200 mm, E: 100 mm, rozpětí 0 – 4000 mm

**Přístrojové vybavení stanice:**

1928 – 2002 přístroj: limnigraf

2002 – dosud přístroj: NOEL – aut. záznam.

**Dno:** přirozené kamenité

**Ovlivnění:** v zimě dochází k ledovým jevům

**Břehy:** levý břeh je přirozený a porostlý vegetací. Pravý břeh je přirozený a jen pod stanicí a do vzdálenosti 4 m na obě strany je opevněn kamenem do betonu.


### 2.2.3 Umístění stanice

Stanice se nachází na pravém břehu v za odbočením do obce Dvorce. Ke stanici se dá přijet po komunikaci č 602 do Hosova nebo z vlakové zastávky v chatové oblasti Dvorce. Stanice je umístěna 50 m pod mostem místní komunikace. Pro lepší orientaci viz obr. [6]



**Obr. 7.** Umístění měrného profilu





**Obr. 8.** Příčný profil měrného profilu Dvorce



**Obr. 9.** Foto měrné stanice a měrného profilu Dvorce

## 2.3 PTÁČOV

### 2.3.1 Základní údaje:

Název stanice:	PTÁČOV
Tok:	Jihlava
Hydrologické číslo:	4-16-01-093
Číslo databanky:	4690
Staničení [km]:	93.20
Plocha povodí [km <sup>2</sup> ]:	963.84
Dlouhodobý průměrný průtok $Q_a$ :	5.510 [m <sup>3</sup> /s]
Dlouhodobý průměrný roční stav:	93.00 [cm]

Tab. 5. Geografické údaje o vodoměrné stanici Ptáčov

Zeměpisné souřadnice		
zem. délka	zem. šířka	Břeh
155612	491255	L

Tab. 6.  $N$ -leté průtoky Ptáčov ( $Q_N - m^3/s$ )

Roky	1	2	5	10	20	50	100
$Q$ [m <sup>3</sup> /s]	45.00	68.00	103.00	132.0	166.00	217.00	260.00

### 2.3.2 Popis stanice

Jedná se o zděnou budovu, která má půdorysné rozměry 2.5 x 3.0 m a výšku 2.5 m bez střechy. Střecha je rovná s oplechováním. Stanice je umístěna na betonovém soklu. Ke stanici vede cesta a přístup k toku je řešen schůdky. Jedná se o novou měrnou stanici, která nahradila starou v roce 2002. [6]

**Šachta:** průměr: 1000 mm hloubka: 4500 mm

**Přívodní kanál:** : průměr: 350 mm hloubka: 3500 mm

**Vodočet:** nadmořská výška nuly 384,75 B.v.p.

- šikmý: plech na dřevu, délka 1100 mm, E: 100 mm, rozpětí 0 – 1000mm
- svislý: plech na dřevu, délka 3400 mm, E: 100 mm, rozpětí 1000 – 4300 mm

#### **Přístrojové vybavení stanice:**

1932 – 2002 přístroj: limnigraf

2002 – dosud přístroj: NOEL – aut. záznam.

**Dno:** přirozené kamenité

**Ovlivnění:** v zimě dochází k ledovým jevům

**Břehy:** pravý břeh je přirozený. Levý břeh je přirozený. Pod měrnou stanicí a v jejím okolí 2 m po toku a 1 m proti toku je opevněn kamenem do betonu.


### **2.3.3 Umístění stanice**

Stanice se nachází na pravém břehu v za odbočením do obce Ptáčov. Ke stanici se dá přijet po komunikaci č. 23 do Vladislavi. Stanice leží u Táborského mlýna pod Ptáčovem a naproti bývalé rukavičkářské továrně [6].



**Obr. 10.** Umístění měrného profilu





**Obr. 11.** Příčný profil měrného profilu Ptáčov



**Obr. 12.** Foto měrné stanice a měrného profilu Ptáčov

### 3 ZPRACOVÁNÍ HISTORICKÝCH DAT

Před započítím vyhodnocování dat bylo zapotřebí nejdříve získání a přepsání dat do digitální formy. Všechny tři stanice byly vybaveny automatickými přístroji až v roce 2002. Díky této skutečnosti musela být data uložená v archivech ČHMÚ ručně přepsána do počítače. To nejdříve byly vyhledány složky měrných profilů, a poté byl procházen rok po roce a hledán největší vodní stav v roce. Záznamy ve složkách byly zaznamenány na milimetrovém papíře na nichž byly vykresleny vodní stavy v cm. Ne vždy byly údaje čitelné či kompletní. Nekompletnost a nečitelnost byla zejména do roku 1965, kdy chyběly právě měsíce s největšími stavy. Byl zde jen list s kulminačním průtokem. Největší problém se vyskytl před rokem 1950, kdy byl k dispozici jen jeden či žádný měsíc. Stavy byly zapisovány na milimetrový papír pomocí psacího pera. Milimetrový papír byl osazený na hodinovém strojků. Pero reagovalo na změnu hladiny v korytě pomocí plováku. Nevýhodou tohoto systému je neoperativnost, a pokud se k papíru dostane vlhkost, tak i nečitelnost. Vzhledem k tomu, že byl každý měrný profil zpracováván samostatně, nejedná se vždy o stejnou povodňovou vlnu [6].

Z těchto výše zmíněných důvodů se předpovědní modely tvořily pro data od roku 1960. Data digitální tvoří téměř 1/3 všech událostí jež se použily pro tvorbu modelů.

## 4 PŘEVOD VODNÍCH STAVŮ NA PRŮTOKY

### 4.1 MĚRNÁ KŘIVKA PRŮTOKŮ (MKP)


Ve vodočetných stanicích se pravidelně odečítají vodní stavy  $h$  a hydrometrickým měřením se stanovují odpovídající průtoky  $Q$  [2]. Každé hodnotě  $h_i$  odpovídá jedna hodnota  $Q_i$ . MKP se v ideálním případě setrojí na základě předchozích hydrometrických měření v daném profilu či na základě hydraulického výpočtu. Profil nesmí být v dosahu vzdutí pohyblivého jezu nebo kolísavého vzdutí recipientu. MKP se vyjadřuje graficky či tabelárně, resp. regresními rovnicemi [2].

V praxi jsou MKP velmi často používány u přirozených říčních koryt pro proložení regresní funkce v mocniném tvaru:

$$Q = a_0 (h + a_1)^{b_1} \quad (1)$$

Přesněji polynomy druhého stupně:

$$Q = a_0 + a_1 h + a_2 h^2 \quad (2)$$



Obr. 13. Měrná křivka průtoku

U obou vztahů jsou  $a_0...a_i$ ,  $b_0...b_j$  regresními koeficienty získanými kalibrací. V případě složitých průtočných profilů, resp. inundací, se měrná křivka vynáší jako lomená. Pro každou křivku pak platí jiná rovnice. [2]

S určitou opatrností je možno průběh měrné křivky prodloužit i za rozsah provedených měření průtoků. I přesto se snažíme vybrat vodoměrné profily tak, aby byly stálé, přesto se průtokové poměry v korytě mění (usazováním, vymíláním, zarůstáním). Vykreslená měrná křivka platí jen dočasně a její tvar se musí neustále upřesňovat novými měřeními průtoků. Musíme si být vědomi toho, že za povodní není průběh měrné křivky jednoznačný, protože ta platí pro ustálené rovnoměrné proudění. Při průchodu povodňové vlny příčným průřezem se při stoupání hladiny zvětšuje sklon, takže nejdříve nastává největší sklon hladiny, posléze největší rychlost, potom největší průtok a nakonec největší vodní stav. Při klesání hladiny je za stejného vodního stavu sklon menší než při stoupání. Měrná křivka pak vytváří smyčku – zdvojuje se (hystereze). Chyba ve stanoveném průtoku za povodní bývá odhadována v intervalu  $\pm 10 \%$ . Rozšířená nejistota  $a$  (chyba  $3\sigma$ ) na obě strany. Je to typ nejistoty  $B$  [2].

Platnost MKP tedy závisí na stabilitě hydraulických podmínek v daném úseku toku a je časově omezena. Může se měnit v důsledku změn příčného či podélného profilu toku po každé větší povodni. V některých profilech, kde má velký vliv stav vegetace, se užívají různé MKP pro letní a zimní období. Informace o platnosti MKP je důležitý doprovodný údaj, který nesmí být přehlédnut [2].

Průběh měrné křivky je při absenci měření možno odhadnout i pomocí vztahů pro ustálené rovnoměrné proudění – např. pomocí Chézyho rovnice. Opakovaně pro postupně se zvětšující průtočnou hloubku vypočteme průtok a příslušné body ( $Q ; h$ ) vyneseme do grafu. Takto stanovená křivka je hladká a je postačující ji proložit čarou (parabolou). Největším problémem však u přirozených koryt představuje odhad drsnosti koryta v uvažovaném profilu. Zde se často uchylujeme k tabulkovým hodnotám, které však mohou být zavádějící. Vždy je dobré takto teoreticky stanovené průběhy měrných křivek v důležitých případech alespoň orientačně ověřit pomocí několika naměřených bodů ( $Q ; h$ ) získaných hydrometrováním [2].

## 5 VYHODNOCENÍ N-LETÝCH PRŮTOKŮ

Kapitola byla zpracována na základě slibu daného v bakalářské práci a jedná se tedy o dokončení vyhodnocení povodňových vln. Funkce pravděpodobnosti překročení (čára překročení) určuje, s jakou pravděpodobností bude náhodná veličina větší nebo rovna hodnotě A. Tato funkce v praxi například udává, s jakou pravděpodobností bude dosažen nebo překročen určitý průtok v daném profilu na toku [2].

### 5.1 ZPRACOVÁNÍ DAT

Vypočtení celkových objemů pro jednotlivé události se provedlo v programu Matlab R2010a. Každá událost byla zapsána do matic. Matice obsahovaly okamžité hodinové průtoky, a protože jednotlivé body se dají proložit přímkou, byla pro výpočet celkových objemů použita numerická integrace. Jako metoda numerické integrace bylo zvoleno složené obdélníkové pravidlo. Pravidlo bylo zapsáno do skriptu. Skript byl aplikován na všechny povodňové události.


### 5.2 SESTAVENÍ ČÁRY PŘEKROČENÍ PRO OBJEMY POVODNÍ

K sestavování čar překročení byl použit program RCPNV (autoři: Menšík, Marton, Starý). Pro konstrukci čar bylo využito rozdělení Johnson, které dává nejlepší výsledky v hydrologii. Rozdělení vyžaduje optimalizaci, kterou provede program sám. Bylo provedeno srovnání čar překročení pomocí rozdělení Johnson, Pearson III, Charlier, Normální (ukázka příloha 3). Dále byly sestaveny empirické a teoretické čáry překročení objemů. Z takto zkonstruovaných čar byly odečteny N-leté objemy povodňových vln.[6]

K tomuto výpočtu byl použit vztah:

$$p = 1 - e^{-\frac{1}{N}}. \quad (5.1)$$

Při zadávání hodnot do programu musely být hodnoty jednotlivých objemů poděleny hodnotou 100 000, protože program RCPNV dokáže vykreslit empirické i teoretické čáry pouze pro hodnoty nepřesahující tisíc, avšak program dokáže spočítat empirické a teoretické čáry i pro hodnoty nepodělené. Hodnoty v tabulkách byly získány z nepodělených hodnot.



**Obr. 14.** Ukázka čáry překročení objemů pro měrnou stanici Batelov

**Tab. 7.** Objemy povodňových vln pro měrný profil Batelov

N – letost	1	5	10	50	100
Objem [mil m <sup>3</sup> ]	0.7	3.36	6.905	24.189	-

**Tab. 8.** Objemy povodňových vln pro měrný profil Dvorce

N – letost	1	5	10	50	100
Objem [mil m <sup>3</sup> ]	2.879	9.928	13.956	22.515	25.284

**Tab. 9** Objemy povodňových vln pro měrný profil Ptáčov

N – letost	1	5	10	50	100
Objem [mil m <sup>3</sup> ]	3.723	13.533	20.245	43.994	59.483

## 6 URČENÍ POSTUPOVÉ DOBY POVODŇOVÝCH PRŮTOKŮ

### 6.1 URČENÍ POSTUPOVÉ DOBY PRŮTOKU

Doba toku je závislá na několika parametrech. Mezi hlavní parametry náleží:

$$Q = f(Q_h, I, K, S, n) \quad (6.1)$$

$Q_h$  ....průtok v horním profilu

$I$ .....sklon hladiny v toku

$K$ .....koeficient charakterizující tvar koryta

$S$ .....délka říčního úseku

$n$ .....drsnost koryta

Hodnoty  $K$  a  $n$  jsou přibližně konstantní, tedy změna postupové doby je v podstatě závislá na kolísání průtoků v horním profilu a podélném sklonu hladiny [2], za předpokladu, že na toku mezi dvěma stanicemi není významné vodní dílo. Toto dílo by mohlo značně svou manipulací ovlivnit průtok, a tím i ostatní parametry postupové doby průtoků.

$$Q = f(Q_h, I) \quad (6.2)$$


### 6.2 KŘIVKY POSTUPOVÝCH DOB PRŮTOKŮ

Prozatím můžeme sestavit závislosti vzájemně si odpovídajících průtoků, avšak my potřebujeme určit i postupovou dobu. Tuto dobu určíme jako funkci průtoků v horním profilu v čase.

$$t, \tau = f(Q_h, t) \quad (6.3)$$

Funkci lze získat rozbořením křivek průtoků horního a dolního profilu a to tak, že si budeme všimnout vzájemných odlehlostí, geneticky si odpovídajících charakteristických částí hydrogramů [2]. Toto řešení je velmi jednoduché. Zakreslíme hydrogram horní i dolní stanice do jednoho hydrogramu. Dále budeme porovnávat doby kulminací a jejich odlehlosti. Mimo kulminací rovněž porovnáme významné lomové body. Samotná postupová doba je pak dána vztahem:

$$T_i = t_{i, Qd} - t_{i, Qh} \quad (6.4)$$




Obr. 15. Určení postupových dob průtoků

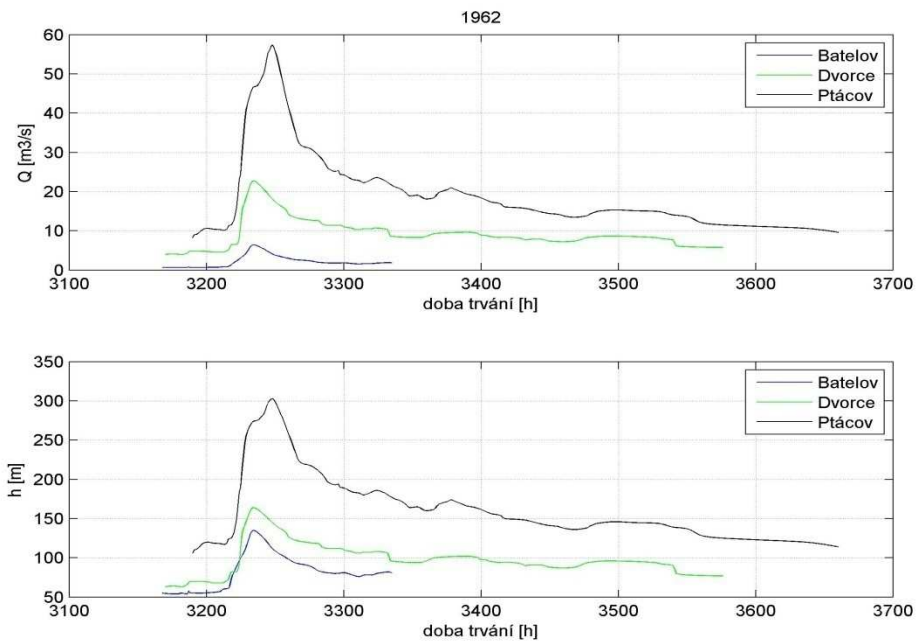
Pro sestavení přesného modelu je zapotřebí znát postupovou dobu povodňové vlny. V naší situaci bylo zapotřebí určit tuto dobu mezi stanicemi Batelov – Dvorce, Dvorce – Ptáčov a Batelov – Ptáčov. Poslední možnost se určila za účelem kontroly předchozích dvou postupových dob, protože by součet mezi postupovou dobou Batelov – Dvorce a Dvorce – Ptáčov měl být roven postupové době Batelov – Ptáčov.

Postupová doba se zjišťovala postupným posouváním průtoku dolní stanice (stanice níže po toku) v čase. Časový posun dolní stanice byl zvolen 1 až 32 hodin s krokem jedna hodina. Kritériem pro posouzení postupové doby byla suma součtu čtverců odchylek mezi časově si odpovídajícími průtoky. Za tímto účelem byla použita data okamžitých hodinových průtoků od ČHMÚ. Uvažovaly se pouze povodňové situace, které měly podobný průběh. Povodně s velmi odlišným průběhem mezi stanicemi se vyřadily.






**Obr. 16.** Nevhodný hydrogram pro postupovou dobu Dvorce - Ptáčov



**Obr. 17.** Ukázka vhodného hydrogramu


Vyhodnocení probíhalo v programu MATLAB R2010a. V tomto programu byly vytvořeny matice, jež obsahovaly průtoky a datумы průtoků pro danou stanici. Tyto matice pak byly za pomoci skriptů transformovány do matic, které obsahovaly data ze dvou stanic. Zde byla pro každou povodňovou situaci vytvořena matice, kde průtok v dolní stanici se postupně posouval v čase o jednu hodinu vpřed a průtok v horní stanici zůstával časově neměnný. Závěrem se

byly vypočteny odchylky mezi časově odpovídajícími průtoky. Doba postupu pak byla určena nejmenší hodnotou kritéria pro danou povodeň.



**Obr. 18.** Ukázka postupové doby Batelov – Dvorce

Lze si snadno povšimnout vysokých hodnot, které leží ve větší vzdálenosti od minima. Zpracováním postupové doby bylo zjištěno, že postupová doba se zkracuje se vzrůstajícím průtokem, a to až do maximálního průtoku, který nezaplaví údolní nivu. Od tohoto průtoku se postupová doba opět prodlužuje.




**Obr. 19.** Závislost postupové doby na průtoku  $Q_h$

Závislosti byly proloženy polynomy. Díky tomu jsme získali závislosti:

$$y = -2.62 + 2.82 x, \quad \text{platný pro } Q_{hmax} (8.8; 14.6), \quad (6.4)$$

$$y = -3.15 + 21.46x, \quad \text{platný pro } Q_{hmax} (5.7; 8.8), \quad (6.5)$$

$$y = 0.216x + 4.626, \quad \text{platný pro } Q_{hmax} (4.1; 5.7). \quad (6.6)$$



**Obr. 20.** Závislost postupové doby na průtoku  $Q_h$

$$y = 6.995x - 27.65, \quad \text{platný pro } Q_{hmax} (28.3; 42.3), \quad (6.7)$$

$$y = 7.11x - 28.57, \quad \text{platný pro } Q_{hmax} (21.2; 28.3), \quad (6.8)$$

$$y = -2.833x + 41.03, \quad \text{platný pro } Q_{hmax} (12.7; 21.2). \quad (6.9)$$

Tento postup měl jedno úskalí. U povodní s velmi rychlým nástupem se ukázalo, že tato metoda je nevhodná.

Takto získané doby doběhů jednotlivých povodňových vln byly využity při vytváření regresních modelů mezi jednotlivými stanicemi. Lze je využít také při odvozování chybějících hydrogramů dle regresních závislostí (viz. kapitola 7.2).

Data a grafy jsou uloženy na přiloženém DVD.

### 6.3 METODA VZÁJEMNĚ SI ODPOVÍDAJÍCÍCH PRŮTOKŮ

Metoda spadá pod krátkodobé hydrologické předpovědi, přesněji řečeno pod hydrometrické. Ty umožňují právě takový předstih předpovědi, jaký jim umožňuje postupová doba z horního do dolního profilu [2].

Metoda se řadí mezi jednodušší. Je založena na sledování vodních stavů (průtoků) v horní a dolní stanici. Ke každému průtoku v horní stanici lze přiřadit odpovídající průtok v dolní stanici.

Nezbytné pro použití této metody je přítomnost měření vodních stavů v daném povodí ve vodoměrných stanicích. Vodní stavy za pomoci měrných křivek jsou převedeny na průtoky. Uvedenou metodu nelze použít tam, kde není průtok v dolní stanici funkcí průtoků horní stanice. Tento případ může nastat, pokud v mezipovodí leží významné vodohospodářské dílo. Toto dílo může velmi silně ovlivnit závislost mezi horní a dolní stanicí. Mezipovodí je oblast povodí mezi horní a dolní měrnou stanicí.

Pro úsek mezi vstupním a předpovědním profilem platí:

$$Q_{t+\tau}^p = Q_t^z + \Delta Q_{t+\tau} . \quad (6.10)$$


Ke stanovení vztahů mezi odpovídajícími si průtoky se obvykle používá stejného podkladového souboru. Volí se většinou grafický způsob znázornění, kde na svislé ose se vynášejí hodnoty průtoků v horní stanici a na vodorovné ose hodnoty dolní stanice [2].

## 7 REGRESNÍ ANALÝZA

Regresní analýza se používá pro jednostrannou závislost. Tato závislost nastává, když na jedné straně stojí nezávislá proměnná a na straně druhé závislá proměnná. Pro nalezení závislosti jsou k dispozici dvojice hodnot  $X$  a  $Y$ . Hodnoty  $X$  by měly být reprezentovány přesnými hodnotami, hodnoty  $Y$  mohou být zatíženy chybami. V našem případě jsou obě veličiny zatíženy chybou ze stanovení průtoku za povodní, která bývá odhadována v intervalu  $\pm 10\%$ . Jedná se o rozšířenou nejistotu  $a$  (chyba  $3\sigma$  na obě strany), typ nejistoty  $B$  [2].


Obecně lze říci, že mezi proměnnými  $X$  a  $Y$  existují tyto vzájemné závislosti [2]:

- Žádná závislost,




**Obr. 21.** Mezi proměnnými  $X$  a  $Y$  není žádná závislost

- Funkční závislost,



**Obr. 22.** Mezi proměnnými X a Y je funkční závislost

- Pravděpodobnostní závislost.



**Obr. 23.** Mezi proměnnými X a Y je pravděpodobnostní závislost

Cílem užití regresní analýzy je proložení naměřených bodů funkcí s nejmenší možnou chybou dle vybrané metody. V případě pravděpodobnostní závislosti lze body proložit regresní křivku [2].


Pro proložení dat si lze vybrat z několika typů závislostí, a to:

- Lineární (přímková),
- Křivková (polynom 2. a vyššího stupně, logaritmická funkce, exponenciální funkce, atd.).

Pro proložení dat byla použita lineární i křivková závislost. Pro křivkovou závislost byly zvoleny polynomy 2. a 3. stupně. Pro nejlepší proložení závislostí bylo užito kritérium součtu nejmenších odchylek čtverců ( $Y_i - \hat{Y}_i$ ) pro přímkovou závislost, polynom 2. a 3. stupně a robustní proložení (přímkovou závislost).

Kritérium pro součet čtverců odchylek:

$$\pi = \sum e^2 = \sum (Y_i - \hat{Y}_i)^2 \quad (7.1)$$




Obr. 24. Zobrazení metody nejmenších čtverců

## 7.1 POSTUP PŘI PROKLÁDÁNÍ REGRESNÍ KŘIVKY SHLUKEM BODŮ[2]

- Určení typu regresní rovnice (lineární, nelineární)
- Kalibrace regresní rovnice (určení neznámých koeficientů)
- Sestrojení regresní křivky
- Posouzení způsobu proložení

Pro způsob posouzení byl použit koeficient determinace. Koeficient udává, jaký podíl pozorování závislé proměnné se podařilo regresí vysvětlit. Koeficient nabývá hodnot (0,1). Čím více se hodnota blíží 1 tím větší bude úspěšnost regrese. Koeficient determinace  $R^2$  nezávisí na počtu X-ových prvků.

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2} \quad (7.1)$$



Obr. 25. Měřený a modelovaný průtok

Nevýhodou námi zvolené metody jsou odlehlé body. Tyto body mohou způsobit značné vychýlení závislostí. Z tohoto důvodu došlo k sestavení varianty obsahující tyto odlehlé body a varianty bez odlehlých bodů.

## 7.2 SESTAVENÍ REGRESNÍHO MODELU

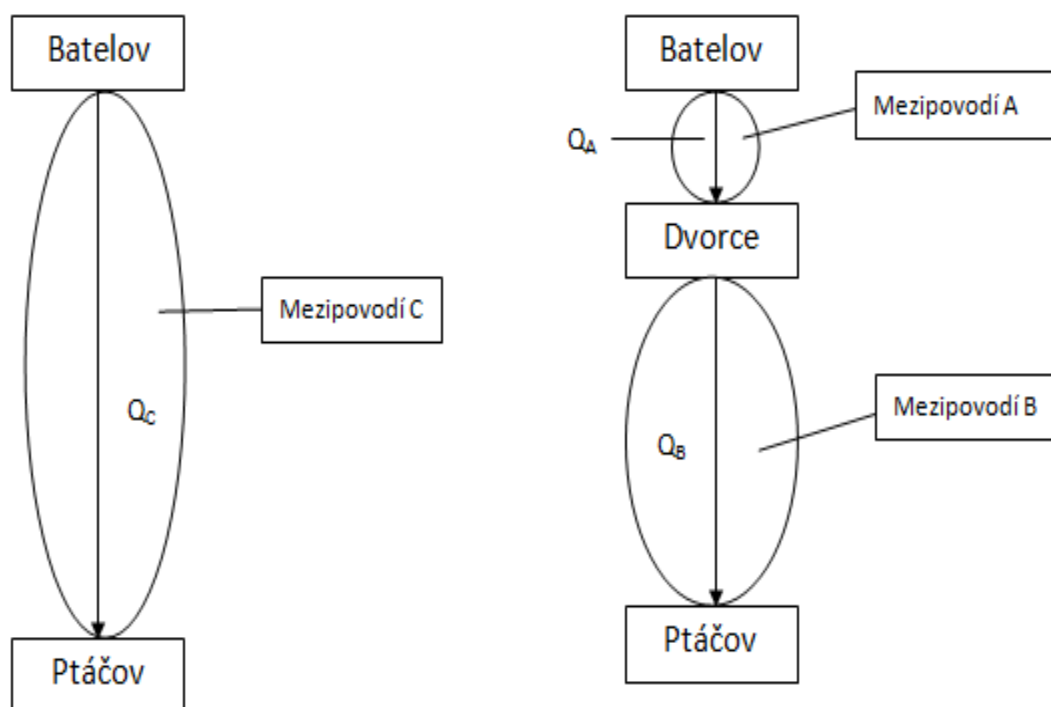
Regresní model se snaží na základě skutečných událostí sestavit systém rovnic. Uvedený systém rovnic umožňuje vysvětlit vztahy mezi proměnnými. Rovnice rovněž umí kvantifikovat vzniklé vztahy. Systém rovnic vyřešil program Matlab R2010a za pomoci QR (orthogonal, triangular) rozkladu.



$$\hat{Y} = a_0 + a_1 X \quad \text{lineární rovnice} \quad (7.2)$$

Nejdříve jsme sestavili schéma řešení. Toto schéma nám umožnilo grafické vyjádření skutečnosti. Díky schématu lze vidět jednotlivé vazby mezi jednotlivými stanicemi.

V našem případě byly sestaveny dva hlavní modely. Tyto modely byly sestavovány pro scénář 1 a pro scénář 2. Scénář 1 je vyobrazen na schématu 1, který odpovídá situaci, kdy potřebujeme předpovídat průtoky v Ptáčově na základě průtoků v Batelově. Scénář 2 je vyobrazen na schématu 2. Uvedený scénář předpovídá průtoky ve Dvorcích na základě průtoků v Batelově a průtoky v Ptáčově na základě průtoků ve Dvorcích. Hodnoty průtoků ve Dvorcích mohou být buď reálnými hodnotami průtoků, nebo hodnotami předpovězených průtoků z Batelova.



**Obr. 26.** Schéma 1 a schéma 2

Ze schémat lze snadno zjistit, že postupová doba Batelov - Ptáčov by měla odpovídat postupové době Batelov – Dvorce - Ptáčov. Vliv mezípodí je zahrnut v regresních vztazích. Časový posun je pro různé průtoky různý. Díky této skutečnosti je pro modely nemožné uvažovat jednu hodnotu postupové doby.

### ***Model 1.1***

Uvedený model nezohledňuje vzestupnou a sestupnou větev povodňové vlny. Bylo pro něj sestaveno 10 – 25 variant (dle stanice), jež se liší postupovou dobou. Každá varianta obsahuje čtyři závislosti (LS, ROB, P2, P3). Rovněž byly sestaveny závislosti obsahující jak odlehlé body, tak závislosti bez odlehlých bodů.

Závislosti jsou:

- lineární dle nejmenších čtverců (LS),
- lineární robustní (ROB),
- polynom 2. stupně (P2),
- polynom 3. stupně (P3).

Na závěr byla dle kritérií vybrána varianta a s ní její závislost s nejmenší chybou.

### ***Model 1.2***

Uvedený model zohledňuje vzestupnou a sestupnou větev povodňové vlny. Z tohoto důvodu musely být vytvořeny matice zvlášť pro vzestupnou a sestupnou větev. Pro rozhodování o konci vzestupné větve byla použita kulminace průtoků v horní stanici. Dále bylo pro něj sestaveno 10 – 25 variant (dle stanice), jež se liší postupovou dobou. Každá varianta obsahuje čtyři závislosti (LS, ROB, P2, P3). Rovněž byly sestaveny závislosti obsahující jak odlehlé body, tak závislosti bez odlehlých bodů.

Závislosti jsou:

- lineární dle nejmenších čtverců (LS),
- lineární robustní (ROB),
- polynom 2. stupně (P2),
- polynom 3. stupně (P3).

Závěrem byla dle kritérií vybrána varianta a s ní její závislost s nejmenší chybou.

## ***Hypotézy***

Byly testovány tyto hypotézy:

- Jaké schéma nabídne lepší hodnoty okamžitých hodinových průtoků v Ptáčově?
- Jaký vliv bude mít na předpovědi vyřazení extrémních průtoků?
- Jaký model nabídne lepší výsledky?
- Je možné zjistit postupovou dobu za pomoci sestavení různých variant modelů s časovým posunem u stanice níže po toku?

Na zvolené hypotézy bude odpovězeno v závěru této kapitoly.


## ***Rovnice modelů***

Rovnice modelů byly získány z regresní analýzy za pomoci programu MatlabR2010a. Postup byl následující:

Nejdříve byly vybrány události, jež se navzájem překrývaly a nevykazovaly extrémní rozdíly (viz. kapitola 6.2). Dále byly vytvořeny matice, jež obsahovaly časově odpovídající si průtoky ve stanicích (Batelov - Dvorce, Dvorce - Ptáčov, Batelov - Ptáčov). Poté byly tyto matice sestaveny i pro časový posun pro různé hodnoty u stanice níže po toku. Dále byly jednotlivé matice sloučeny do jedné velké matice obsahující všechny události mezi stanicemi. Na takto vzniklou matici byly použity vestavěné regresní metody programu Matlab. Za hodnotu X se považoval vždy průtok v horní stanici a za hodnotu Y průtok v dolní stanici. Za pomoci těchto metod jsme získali koeficienty pro jednotlivé regresní závislosti. Koeficient determinance byl spočten za pomoci napsaného skriptu. Při sestavování regresních vztahů bylo zjištěno přehušťení pro nižší průtoky a určitá odlehlost bodů. Vzhledem k velkému množství dat a časovému rozložení jednotlivých událostí, nebyla tato odlehlost nijak zásadní.

Nejprve byly vytvořeny závislosti pro model 1.1 a až poté pro model 1.2. Rovněž byly vytvořeny závislosti pro všechny události a zvláště pro extrémní průtoky, jež obsahovaly oba modely. Do závislostí byly uvažovány všechny průtoky bez jakékoliv selekce.

Ukázka skriptu bude v příloze 2.



**Obr. 27.** Ukázka závislosti

### ***Ověření modelů***


Modely se ověřovaly dle čtyř kritérií. Tato kritéria byla aplikována na všechny události bez výjimek. Jako první kritérium slouží koeficient determinance  $R^2$ . Jelikož hodnota koeficientu se pohybovala pro všechny varianty obou modelů v rozmezí (0, 1), všechny závislosti tuto podmínku splnily. Toto kritérium nebylo určující, protože u většiny událostí bylo velmi podobné. Dále bylo toto kritérium použito u hydrogramů.

Druhé kritérium bylo vizuální posouzení, které probíhalo po sestavení jednotlivých hydrogramů. Porovnávaly se hydrogramy vzešlé z modelů se skutečnými hydrogramy.


Třetí a čtvrté kritérium byly zavedeny z důvodu neschopnosti rozhodnout o nejlepší rovnici na základě vizuálního kritéria. Třetí kritérium je suma čtvercových odchylek okamžitých hodinových průtoků. Uvedené kritérium se však ukázalo nedostatečným při zjišťování postupových dob. Z toho důvodu bylo zavedeno čtvrté kritérium. Toto kritérium je suma čtvercových odchylek objemů. Díky tomuto kritériu bylo možno nejen vybrat nejlepší vztahy a tím i model, jež dává nejlepší výsledky, ale zjistit postupové doby jednotlivých událostí.

### ***Zhodnocení***

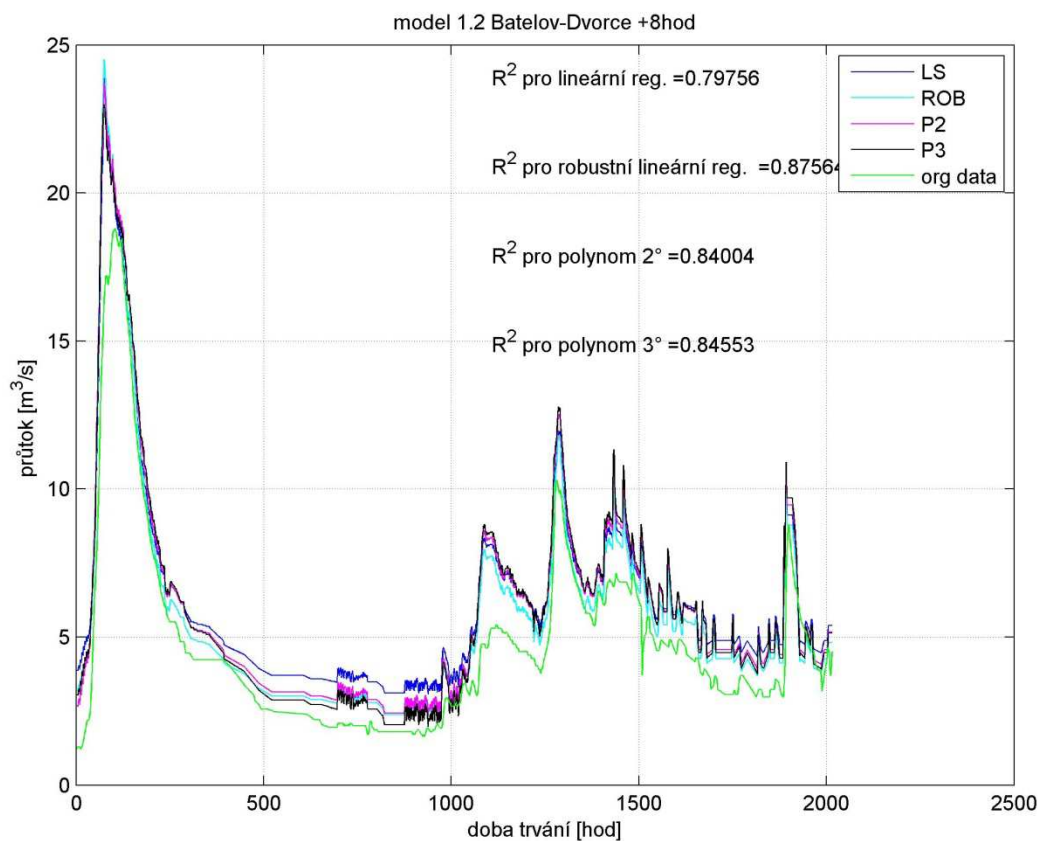
Hodnoty koeficientu determinace pro závislosti kolísaly v rozmezí 0.88 - 0.10. Nejlepší předpovědi pro všechny události mezi stanicemi Batelov – Dvorce dával model 1.2 s časovým posunem +1 a +8 hodin pro závislosti polynomu 2. a 3. stupně. Model byl schopen předpovědět povodňové události ve Dvorcích na základě průtoků v Batelově s koeficientem determinace nabývajícím hodnot od 0.48 do 0.96 a s mediánovou hodnotou 0.78. Lze tedy říci, že model 1.2 dosáhl velmi dobrých výsledků pro celkový průběh povodňové vlny. Model byl nevyhovující pro dvě události, kde hodnota koeficientu determinace klesla pod hodnotu 0.1 Tyto události byly vyřazeny. Pro předpovídání kulminační hodnoty si u modelu 1.2 vedla lépe závislost s časovým posunem +8 hodin, která předpověděla kulminační průtok s chybou 5% - 15%. Model 1.1 si pro tyto stanice nevedl o mnoho hůře, avšak nedosahoval výsledků, jež byly dosaženy modelem 1.2. Pro model 1.1 byly zvoleny závislosti polynomu 2. a 3. stupně. Model 1.1 dokázal předpovědět kulminační průtoky s menší přesností než u modelu 1.2.



**Obr. 28.** Ukázka hydrogramu pro model 1.2




**Obr. 29.** Ukázka hydrogramu pro model 1.2



**Obr. 30.** Ukázka hydrogramu pro model 1.2


Pro stanice Dvorce – Ptáčov vykazovaly nejlepší výsledky závislosti modelu 1.2 s časovým posunem +1 hodina pro lineární závislost. Závislost nedokázala předpovědět povodňové vlny s takovou přesností, jaké bylo dosaženo u stanic Batelov – Dvorce. Koeficient determinace se pohyboval v rozmezí hodnot 0.3 – 0.88. Pro model 1.2 i model 1.1 byly sestaveny i závislosti bez největší povodňové události. Odstranění této události vedlo k výraznému zhoršení předpovědní schopnosti modelu. Model 1.2 předpovídal kulminační průtoky s chybou do 30%. Model 1.1 byl podstatně horší pro předpovídání kulminačních průtoků.



**Obr. 31.** Ukázka hydrogramu

Pro stanice Batelov – Ptáčov měla nejlepší výsledky závislost modelu 1.2 s časovým posunem + 2 hodiny pro lineární závislost. Tato závislost vykazovala dobré předpovědní schopnosti pro celkový průběh povodňové vlny, avšak pro kulminační průtok vykazovala chybu 20 – 50%. Chyba přes 30 % se vyskytla pouze u čtyř událostí. Koeficient determinace nabýval hodnot (0.35-0.9). Model 1.2 dokázal předpovědět některé události lépe než model 1.2 Dvorce – Ptáčov. U největší povodňové vlny dosáhl model 1.2 Batelov – Ptáčov výrazně lepších výsledků než předpověď z měrné stanice Dvorce. Model 1.1 poskytoval dobré výsledky, avšak nedosáhl kvalit modelu 1.2.







**Obr. 32.** Ukázka hydrogramu

Model 1.2 dokázal předpovídat povodňové vlny lépe než model 1.1. Toto zjištění dokazuje, že události mají jinou závislost pro vzestupnou a sestupnou část vlny. Na druhou stranu model 1.1 poskytl rovněž dobré výsledky, a proto jej můžeme rovněž využít při předpovědích. Odstranění extrémních průtoků výrazně zhoršilo předpovědní schopnosti obou modelů. Důvodem bylo přílišné vychýlení závislosti. Toto zjištění bylo překvapující, protože byl očekáván opak. Model 1.2 Dvorce – Ptáčov a model 1.2 Batelov – Dvorce předpovídaly podobné průběhy vln, avšak u některých vln se velmi lišily. Pro tyto události jeden z modelů vykazoval výrazné nepřesnosti. Jako lepší model pro předpověď průtoků v Ptáčově se jevil model 1.2 Batelov – Ptáčov. Pro předpovědi lze využít i závislosti s vyšším časovým posunem. Koeficient determinace je nižší oproti jeho nejlepším hodnotám až o 0.1, a proto předpovědi dosahují nižší předpovědní schopnosti. Kompletní přehled hydrogramů pro modely 1.1 a 1.2 je přiložen na DVD.


## Srovnání modelu 1.2 Batelov – Dvorce a 1.2 Dvorce a Ptáčov




Obr. 33. Ukázka hydrogramu



Obr. 34. Ukázka hydrogramu



**Obr. 35.** Ukázka hydrogramu



**Obr. 36.** Ukázka hydrogramu

## 8 MODEL Y VYUŽÍVAJÍCÍ NEURONOVÉ SÍTĚ


Umělé neuronové sítě, dominují v rozpoznávání okamžité závislosti ze vzorů stupně výstupních vztahů [2]. Neuronové sítě je výhodné použít v modelech pro svou schopnost rychlého rozpoznání funkční i silně nelineární závislosti mezi vstupními a výstupními údaji. Jejich výhodou oproti regresním rovnicím je, že se nemusí složitě hledat závislostní vztahy. Po natrénování rovněž vynikají svou rychlostí pro převedení vstupů na výstupy. Problémem u umělých neuronových sítí je extrapolace dat mimo oblast tréninkových dat, protože neuronové sítě nejsou k danému účelu určeny.

V této práci se nebudeme zabývat složitou problematikou neuronových sítí a jejich strukturou, ale využijeme zde jen schopnosti pro predikci povodňových průtoků v dolní stanici na základě měření v horní stanici. Pro predikci průtoků jsme využili Neural toolbox programu Matlab R2010a. Dále v textu jsou popsány základní charakteristiky neuronových sítí a modely, jež je využívají.

### 8.1 UMĚLÉ NEURONOVÉ SÍTĚ

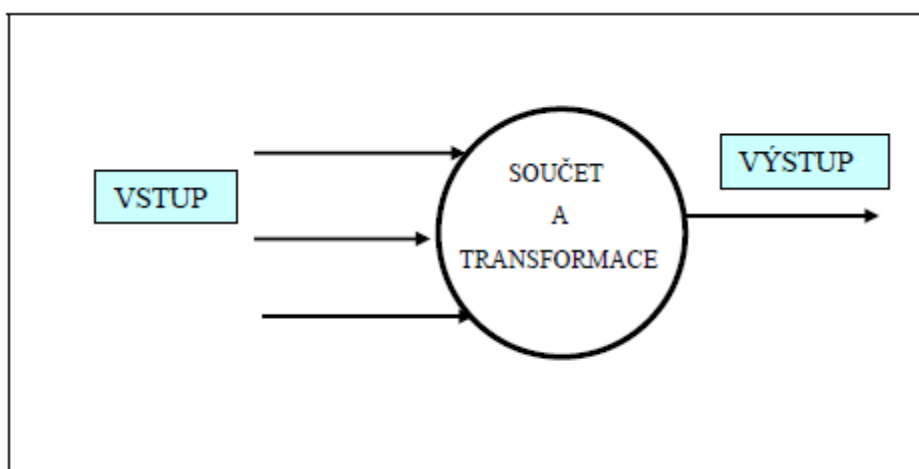
#### 8.1.1 Základní pojmy

Umělé neuronové sítě pracují obdobně jako neuronové buňky lidského mozku. Neuronové buňky lidského mozku se skládají z těla neuronu (*somy*), výběžků (dlouhé, krátké). Výběžky vedou signály do *somy*, zde se jednotlivé signály sečtou a vyhodnotí se s jakou intenzitou a zda má být signál dál poslán. Rozeznáváme dva typy výběžků a to: krátké výběžky (*dendrity*) přenášející signál do *somy* a dlouhé výběžky (*axony*) přenášející signál s různou velikostí spoždění ze *somy* k dalším *dendritům*, které dále šíří signál až do cílových neuronových buněk.



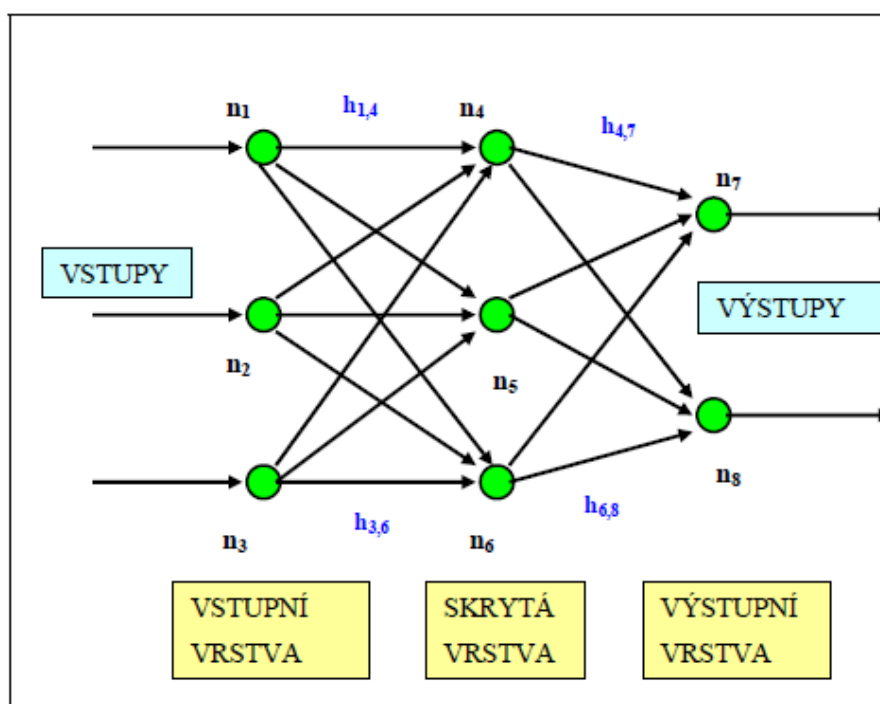
**Obr. 37.** Biologický neuron

Umělý neuron se chová podobně jako neuron biologický. Přijímá vstupní signály (vstupy) a vysílá výstupní signály (výstupy). Každý neuron přijímá vstupy z mnoha neuronů[2].



**Obr. 38.** Umělý neuron

Neuronová síť je definována jako orientovaný graf  $G(N, H)$ , ve kterém množinu vrcholů  $N$  tvoří těla neuronů ( $n_i$ ) a množinu hran  $H$  tvoří spojnice neuronů ( $h_{ij}$ ). Jednotlivé neurony v grafu jsou uspořádány do vrstev tak, že vstupní vrstvu tvoří vstupní neurony, dále následují skryté vrstvy neuronů a vrstva výstupních neuronů. Každý neuron v libovolné vrstvě je spojen hranou s každým neuronem vrstvy předchozí i vrstvy následné [2].




Obr. 39. Neuronová síť

### 8.1.2 Přenosové funkce

Neuronové sítě mohou využívat širokou škálu neuronových sítí. Mezi nejčastěji využívané přenosové funkce patří sigmoida, skoková, lineární prahová, gausova, lineární a lineární satureovaná přenosová funkce.

V modelu obsahující neuronové sítě byly zvoleny jako přenosové funkce sigmoida a lineární přenosová funkce. Sigmoidální funkce je nelineární, spojitá a spojitě diferencovatelná. Má mnoho žádoucích vlastností pro využití v neuronových sítích. Lze ji za pomoci strmosti  $\beta$  měnit. Metoda zpětného šíření aplikovaná na síť s touto funkcí velmi rychle konverguje ke správnému řešení minimalizačního problému.



Obr. 40. Sigmoida  $\beta = 0.25$

### 8.1.3 Metody trénování

#### *Metoda zpětného šíření (back-propagation)*

Tato metoda se velmi často používá v oblasti jednosměrných neuronových sítí. Lze ji přiřadit mezi gradientní metody. Při jejím užití se síť postupně učí pomocí korekce vah v závislosti na odchylce mezi zadanou a vypočtenou hodnotou výstupních signálů ve výstupních neuronech neuronové sítě. Korekce signálů (vah) probíhá sítí zpětně od výstupní vrstvy neuronů po vrstvu vstupní. Proces trénování sestává z postupně opakujících se výpočtů výstupů z neuronové sítě při daných vahách pro každý vzor, kdy signály postupují od vstupní do výstupní vrstvy neuronů a je vypočtena chyba vzoru  $E_v$ . Následně pak probíhá zpětným směrem postupný výpočet oprav jednotlivých vah. Metoda je funkční v naprosté většině testovaných příkladů [2].

### 8.1.4 Způsob trénování

Nechť je dána tréninková matice  $A$ , která obsahuje v určitých sloupcích hodnoty vstupních signálů a ve zbývajících sloupcích hodnoty výstupních signálů. Vždy jeden řádek odpovídá jednomu vztahu mezi vstupem a výstupem – tvoří jeden vzor [2].

V průběhu učení (trénování) vstupují postupně do neuronové sítě (NS) vstupní signály, které nazýváme tréninkovými vzory. V závislosti na velikostech vah a prahů pak vystupují z výstupních neuronů hodnoty výstupních signálů. Postup se opakuje podle počtu řádků tréninkové matice. Zadané výstupní signály a NS vypočtené pro každý vzor zvlášť jsou chyby vzoru  $E_v$ . Součet čtverců těchto odchylek vypočtených ze všech vzorů je chybou vzoru  $E$ . V procesu trénování se hledají takové hodnoty vah, aby pro všechny řádky tréninkové matice tyto odchylky nepřekročily povolenou toleranci [2].

V námi uvažovaných neuronových sítích byly jako vstupy uvažovány vždy průtoky v horní měrné stanici. Průtoky v horní stanici byly postupně posouvány v čase. Za výstup byl pak považován průtok v dolní měrné stanici, který v čase posouván nebyl.

## 8.2 POSTUP VYTVÁŘENÍ PŘEDPOVĚDNÍHO MODELU OBSAHUJÍCÍHO NEURONOVÉ SÍTĚ


Pro tvorbu předpovědního modelu bylo vybráno prostředí programu Matlab R2010a. Neuronové sítě byly vytvářeny za pomoci Neural toolboxu jež je součástí programu Matlab. Celkově byly vytvořeny dva základní modely. Modely byly vytvořeny vždy pro dvě měrné stanice Batelov – Dvorce, Dvorce – Ptáčov, Batelov – Ptáčov. Pro každý z modelů byly vytvořeny tři základní varianty. První varianta neuvažuje rozdělení na sestupnou a vzestupnou větev povodňové události na rozdíl od varianty druhé. Každá varianta modelu obsahuje podvarianty s časovým posunem horní stanice vždy po jedné hodině dopředu.

Data pro vytváření tréninkových, testovacích a validačních matic jsou shodná s daty z kapitoly 7.2. Data byla rozdělena v následujícím poměru. Tréninková data tvoří 70% z celkové množiny dat, zatímco validačním i testovacím datům náleží po 15% z celkové množiny dat. Data jsou rozdělována do kategorií náhodně.

V následujících podkapitolách budou postupně představeny předpovědní modely a jejich varianty.

### 8.2.1 Obecný popis neuronové sítě v modelech

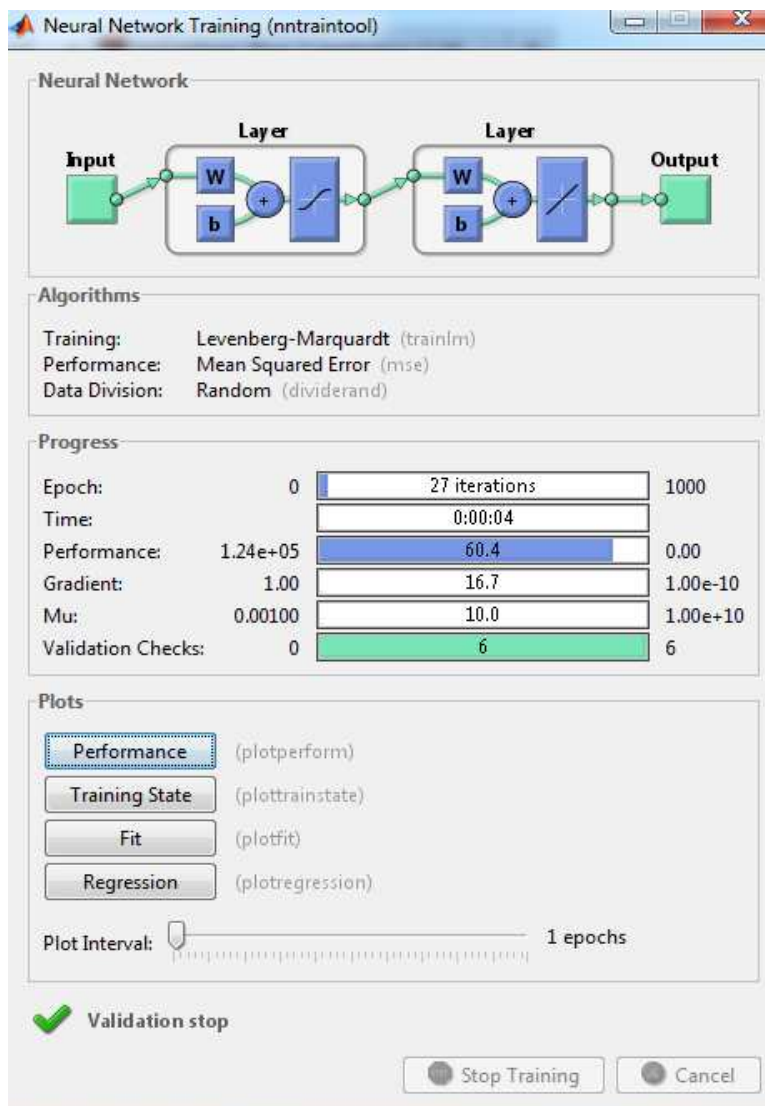
Pro oba modely byly neuronové sítě sestavovány za pomoci Neural toolboxu. Jako výchozí neuronová síť byla zvolena dvouvrstvá perceptronová síť. První skrytá vrstva neuronů obsahuje pevný počet 20 neuronů. Byly testovány i varianty s vyšším počtem skrytých neuronů v první vrstvě, avšak to vedlo k přetrénování neuronové sítě. Naopak nižší počet neuronů snižoval přesnost předpovědního modelu. Výše zmíněná skrytá vrstva používá jako transformační funkci sigmoidu. Druhou skrytou vrstvou je výstupní vrstva, která obsahuje proměnný počet neuronů. Počet neuronů je roven počtu řádků matice dat po rozdělení do kategorií. Výstupní vrstva používá jako transformační funkci lineární transformační funkci.



Obr. 41. Ukázka neuronové sítě




Pro trénování neuronové sítě byla zvolena metoda zpětného šíření. Ukončení trénování nastane po proběhnutí 1000 iterací nebo při poklesu celkového součtu čtverce chyb  $E$  pod hranici spočtenou toolboxem.



**Obr. 42.** Neural toolbox programu Matlab R2010a

Celý proces trénování je řízen dle Marquardt-Levenbergova algoritmu. Pro případ velkého množství dat lze využít i jeho redukovanou verzi. Po skončení procesu trénování toolbox spočítal hodnoty validace, a poté i hodnoty pro testovací data. Pokud obě kontroly nepřekročily povolenou mez chyby, toolbox pokračoval v trénování další neuronové sítě. Celý proces tvorby modelu probíhal za pomoci napsaného skriptu. Skript postupně vytvářel matice pro trénování a poté si zavolal toolbox pro trénování neuronové sítě. Dále vykreslil grafy pro průběh trénování, validace, testování a závislosti reálných průtoků a průtoků předpovídaných neuronovou sítí. V grafech závislostí byl počítán koeficient determinace

přímo toolboxem, a proto byl označen písmenem *R*. Nakonec skript provedl výpočet koeficientu determinace a vykreslil graf pro povodňovou událost předpovězenou modelem a z reálných dat.



**Obr. 43.** Ukázka závislosti vytvořené neuronovou sítí

### 8.2.2 Modely varianta 1


Tento model nerozlišuje sestupnou a vzestupnou větev povodňové události. Pro model byly sestaveny podvarianty pro různé postupové doby povodně. Model obsahuje jednu neuronovou síť pro každou podvariantu. Pro tvorbu modelu byla použita data z regresního předpovědního modelu 1.

### 8.2.3 Modely varianta 1.1


Tento model obsahuje dvě neuronové sítě pro každou podvariantu. První neuronová síť je trénována na datech vzestupných větví, zatímco druhá neuronová síť je trénována daty sestupných částí větví. Data jsou rozdělena do kategorií (trénovací, testovací, validační) dle kapitoly 8.2. Pro tvorbu modelu byla použita data z regresního předpovědního modelu 1.2.

#### *Problémy při trénování modelů*

Jediný problém vznikl při trénování neuronových sítí, kdy docházelo k jejich přetrénování. Tento problém nejčastěji vznikl v modelu Batelov – Ptáčov, který byl velmi citlivý na přetrénování. U tohoto modelu muselo docházet i k několikanásobnému trénování. Nejhorší situace nastala pro variantu 1.1 při trénování sítě pro vzestupnou síť. Přetrénování se projevovalo obrovskými ústřely v závislosti průtoků, kdy průtok byl i padesátkrát větší než by měl být. Druhým projevem přetrénování bylo velké rozkolísání průtoků. Problém se vždy odstranil přetrénováním.



**Obr. 44.** Ukázka přetrénování neuronové sítě




**Obr. 45.** Ukázka druhotného přetrénování

### 8.3 MODEL BATELOV- DVORCE

Pro uvedený předpovědní model byly očekávány nejlepší výsledky. Důvodem byla menší odlehlost měrných stanic než u ostatních modelů, a proto byly stanoveny přísnější kritéria pro přijatelné výsledky.

#### 8.3.1 Kritéria úspěšnosti modelu

Pro posouzení úspěšnosti předpovědi byla zvolena tři kritéria. Prvním kritériem byla optická shoda mezi předpovědí vycházející z předpovědního modelu a reálnými hodnotami naměřenými v měrné stanici. Druhým kritériem byl koeficient determinace  $R^2$ , který byl počítán za pomoci skriptu viz kapitola 7.1. Toto kritérium bylo splněno, pokud koeficient determinace dosáhl minimálně hodnoty 0.25 a maximálně hodnoty 1. Model byl uznán za platný, pokud maximálně tři události této hodnoty nedosáhly. Třetím kritériem byla maximální chyba kulminačního průtoku. Tato chyba mohla dosáhnout hodnoty 20%. Pokud bylo jedno z kritérií překročeno, síť musela být přeučena.




**Obr. 46.** Ukázka předpovědi modelem Batelov – Dvorce varianta 1

### 8.3.2 Hodnocení úspěšnosti modelu

Uvedený model byly použity obě varianty modelu. Velkým překvapením byly téměř stejné výsledky, jenž byly poskytnuty oběma variantami modelu. Pro obě varianty bylo sestaveno 10 podvariant, jež se lišily časovým posunem v horní stanici. Model dosáhl pro obě varianty lepších výsledků než regresní předpovědní model 1.2.


Žádná varianta modelu nedokázala dodržet přísné třetí kritérium, které bylo maximální chyba v kulminačním průtoku do 20%. Z tohoto důvodu bylo toto kritérium posunuto na hranici 25%. S novou hodnotou kritéria bylo možno model klasifikovat jako úspěšný. Nejlepších výsledků pro obě varianty modelu byly dosaženy pro hodnoty postupové doby 5 až 8 hodin. Nejmenší chyby pro kulminační průtoky dosáhly varianty pro postupovou dobu 8 hodin. Chyby pro kulminační průtok se pohybovaly v rozmezí 1 až 25%. Model měl nejlepší

předpovědní schopnost pro události s vyšší N-letostí. Pro vyšší hodnoty postupové doby model ztrácel velmi rychle svou předpovědní schopnost. Druhé kritérium ( $R^2$ ) bylo porušeno jen ve dvou případech, a proto tyto události byly vyřazeny z hodnocení modelu. Jednalo se o stejné události, které nedokázal regresní model 1.2 správně předpovědět. Nejlepších hodnot koeficientu determinace bylo dosaženo rovněž pro události s vyšší N-letostí, avšak i pro události s nižší N-letostí bylo dosaženo velmi dobrých výsledků.




**Obr. 47.** Ukázka předpovědi varianty 1

Model tedy ukázal velmi dobrou předpovědní schopnost pro drtivou většinu událostí. U ostatních událostí dokázal předpovědět události s uspokojující přesností. Nakonec bylo rozhodnuto, že hlavní variantou se stane varianta 1. Důvodem k tomuto rozhodnutí byla stejná předpovědní schopnost a nižší složitost modelu. Varianta 1 obsahuje jen jednu neuronovou síť a nerozlišuje vzestupnou a sestupnou větev.



**Obr. 48.** Ukázka závislosti mezi horní a dolní stanicí

Zbytek grafů a výstupů varianty 1.1 pro tento model bylo uloženo na DVD. Další ukázky výstupů je možno najít v příloze 1.



**Obr. 49.** Ukázka validace, testování a trénování

## **8.4 MODEL DVORCE – PTÁČOV**

Pro uvedený model byly použity obě základní varianty. Základní varianty byly zpracovávány pro data obsahující všechny události a pro data bez největší události. Vzhledem k větší odlehlosti měrných stanic byla kritéria pro posouzení úspěšnosti modelu mírnější než u modelu Batelov – Dvorce.

### **8.4.1 Kritéria úspěšnosti modelu**


Byla zvolena celkem tři kritéria, která musí model splnit. Prvním kritériem byla optická shoda mezi předpovědí získanou z předpovědního modelu a reálnými daty získanými z měrné stanice. Druhým kritériem byl koeficient determinace, který nesměl klesnout pod hodnotu 0.15 u více než 5 povodňových událostí. Posledním kritériem byla maximální chyba kulminačního průtoku. Ta nesměla překročit hodnotu 30% pro více než 6 událostí. Pokud bylo jedno z kritérií překročeno, musela být síť přeučena nebo varianta modelu byla vyřazena.

### **8.4.2 Hodnocení úspěšnosti modelu**

Nejdříve se sestavila varianta 1 obsahující všechny události. U varianty byla očekávána podobná předpovědní schopnost jako u regresního modelu 1.1, avšak již při vykreslování grafů závislosti bylo dosahováno nízkých hodnot koeficientu determinace. Důvodem bylo rozdělení dat na dvě části.

Po natrénování neuronové sítě se přikročilo k vykreslování předpovědí z modelu, avšak model nebyl schopen předpovídat události s požadovanou přesností. Po mnoha pokusech o přetrénování neuronové sítě bylo rozhodnuto, že varianta 1 obsahující všechna data je nepoužitelná.







**Obr. 50.** Ukázka závislosti pro variantu 1 a pro postupovou dobu +4h

Druhou sestavovanou variantou byla varianta 1 bez největší události, avšak opět se vyskytl podobný problém jako u varianty obsahující všechna data. Výsledky předpovídané modelem měly nižší předpovědní schopnost než u předchozích dat, a proto bylo přikročeno k zavržení varianty 1 modelu Dvorce – Ptáčov.

Dále bylo přikročeno k sestavování modelu pro variantu 1.1. U varianty 1.1 došlo nejdříve k sestavení předpovědního modelu pro data bez největší události. Při vykreslování závislosti se ukázalo, že koeficient determinace dosahoval mnohem vyšších hodnot než u varianty 1. Model dosahoval mnohem lepších výsledků než varianta 1.1 a dokonce překonal předpovědi regresního modelu 1.1 Dvorce – Ptáčov. Bohužel nedokázal dosáhnout kvalit regresního modelu 1.2 Dvorce – Ptáčov.




**Obr. 51.** Ukázka závislosti pro variantu 1.1 bez největší události pro časový posun +7h



**Obr. 52.** Ukázka hydrogramu variantu 1.1

Posledním sestavovaným modelem byla varianta 1.1 obsahující všechna data. Varianta dokázala již při vykreslování závislostí dosáhnout nejlepších výsledků. Při vykreslování samotných předpovědí ukázal model nejlepší výsledky ze všech čtyř sestavovaných variant. Model dokázal překonat i regresní model 1.2 Dvorce – Ptáčov (D-P). Dokázal předpovědět s vysokou přesností i problematickou největší událost, kterou regresní model 1.2 D-P předpovědět nedokázal. U modelu bylo dosaženo nejlepších výsledků pro hodnoty postupové doby 5, 8 až 11 hodin. V celkové bilanci nebyla chyba kulminačního průtoku překročena více než šestkrát, pro většinu hodnot se pohybovala okolo 20%. Hodnoty koeficientu determinace se pohybovaly v rozmezí hodnot 0.4 – 0.9. Pouze pro jednu událost bylo dosaženo hodnoty nižší než 0.2, a proto byla tato událost vyřazena z celkového hodnocení.



**Obr. 53.** Ukázka hydrogramu

Pro předpovídání průtoků mezi měrnými stanicemi Dvorce - Ptáčov byl zvolen model 1.1 obsahující všechny události s hodnotou postupové doby 11 hodin.

## **8.5 MODEL BATELOV – PTÁČOV**

Pro uvedený model byly použity obě základní varianty. Základní varianty byly zpracovávány pro data obsahující všechny události a pro data bez největší události. Vzhledem k největší odlehlosti měrných stanic byla kritéria pro posouzení úspěšnosti modelu mírnější než u modelu Batelov – Dvorce. Velkým problémem se ukázalo trénování neuronových sítí. Velmi často sítě byly sítě přetrénovány, a proto dávaly nesmyslné výsledky. Nejhorší situace nastala pro neuronovou síť vzestupné větve, kde síť velmi často oscilovala mezi hodnotami a uštělovala mimo rozumné hodnoty viz. kapitola 8.2.1

### **8.5.1 Kritéria úspěšnosti modelu**

Úspěšnost modelu byla hodnocena na základě tří kritérií. Prvním kritériem byla optická shoda mezi průtoky získaných z reálných dat a průtoky předpovídanými modelem. Pro tento model měla optická shoda největší váhu pro výběr nejlepší varianty modelu. Důvodem byly velmi malé průtoky v měrném profilu Batelov oproti průtokům v měrném profilu Ptáčov. Druhým kritériem byl koeficient determinace, který nesměl u více jak tří událostí klesnout pod hodnotu 0.2. Posledním kritériem byla chyba v kulminačním průtoku. Ta nesměla překročit hodnotu 60% pro více jak 5 událostí. Model byl považován za úspěšný, jestliže splnil všechna kritéria. V opačném případě došlo k přetrénování neuronové sítě.


### **8.5.2 Hodnocení úspěšnosti modelu**

Pro model byly sestaveny obě varianty, které byly sestaveny na základě dat obsahujících všechny události a z dat neobsahujících největší povodňovou událost.

Nejdříve byla sestavena varianta 1 bez největší povodňové události, avšak již při výstupu závislostí byly rozpoznány výrazné nedostatky modelu. Při vykreslení závislostí neměl model dostatečnou optickou shodu, která byla očekávána. Z výše zmíněných důvodů byl model zavržen.


Druhým sestavovaným modelem byla varianta 1 obsahující všechny události. Model vykazoval uspokojující výsledky při vykreslování závislostí mezi reálnými daty a

předpověďmi. Závěrečné vykreslování ukázalo dobrou optickou shodu. Koeficient determinace nabýval uspokojujících hodnot, avšak nedokázal překonat regresní model 1.2.




**Obr. 54.** Ukázka závislosti pro variantu 1.1 a pro postupovou dobu +2h

Třetím modelem byla varianta 1.1 bez největší události. Bohužel tato varianta nebyla schopna dosáhnout kvalit předchozího modelu. Model měl velké problémy s předpovídáním velkých povodňových průtoků, a proto se nehodil pro povodňové události s vyšší N-letostí.



**Obr. 55.** Ukázka hydrogramu pro variantu 1.1

Posledním sestavovaným modelem byla varianta 1.1 obsahující všechny povodňové události. Uvedený model ukázal překvapivě velmi dobré předpovědní schopnosti, které byly značně nad hranicí očekávání. Při vykreslování událostí z reálných dat a z předpovězených dat bylo dosaženo lepších optických shod než u regresního modelu 1.2. Model rovněž vykazoval velmi dobré výsledky pro koeficient determinace. Pouze pro jedinou událost hodnota koeficientu klesla pod hodnotu 0.2, a proto byla tato událost vyřazena. Nejlepších výsledků bylo dosaženo pro události s vyšší N-letostí s dobou doběhu 8 hodin. Chyba kulminací se pohybovala v rozmezí 10 až 45%.




**Obr. 56.** Ukázka hydrogramu pro variantu 1.1


Model s variantou 1 obsahující všechny události měl velmi dobré výsledky, avšak poslední model vykázal podstatně lepší předpovědní vlastnosti. Z výše zmíněného důvodu byla vybrána varianta 1.1 obsahující všechny události za hlavní variantu modelu Batelov – Ptáčov, protože její předpovědní schopnosti převážily nad její složitostí.

### 8.5.3 Srovnání modelu Dvorce – Ptáčov a Batelov – Ptáčov


Byla srovnávána jen nejlepší varianta z obou předpovědních modelů, ačkoliv model Dvorce – Ptáčov vykazoval velmi dobré výsledky, byl překvapivě poražen modelem Batelov – Ptáčov (B-P) v hodnotách koeficientu determinace. Na druhou stranu model Dvorce – Ptáčov (D-P) dokázal předpovědět jednu událost výrazně lépe než model B-P, a proto lze používat oba předpovědní modely.




Obr. 57. Ukázka hydrogramu



Obr. 58. Ukázka hydrogramu



**Obr. 59.** Ukázka hydrogramu




**Obr. 60.** Ukázka hydrogramu



## 8.6 MODEL S NEURONOVOU SÍTÍ 2.0


Pro model byl zvolen odlišný postup tvorby neuronové sítě než u modelu s variantami 1 a 1.1. Byla zde použita dvouvrstvá perceptronová síť. První skrytá vrstva obsahovala 20 skrytých neuronů a za přenosovou funkci používala sigmoidu, byla tedy stejná jako u předchozího modelu, avšak druhá skrytá vrstva obsahovala jen jeden skrytý neuron. Druhá skrytá vrstva používala stejně jako předchozí model lineární transformační funkci. Rozdělení dat na tréninkové, validační a testovací bylo provedeno dle kapitoly 8.2.1. Zásadní rozdíl byl v tvorbě matice vstupů. Matice obsahovala stejný počet sloupců, který byl roven maximální předpokládané hodnotě postupové doby. Jeden sloupec obsahoval průtoky z horní měrné stanice pro určitou hodnotu postupové doby. Každý sloupec obsahoval stejný počet hodnot. Oproti tomu vzorová matice obsahovala jen jeden sloupec, který měl stejný počet řádků jako matice vstupů. Matice obsahovala průtoky z dolní měrné stanice pro maximální předpokládanou hodnotu postupové doby.

Narozdíl od předchozího modelu byl ponechán výběr vhodných vazeb na modelu. Model musel sám rozeznat funkční a nefunkční závislosti, a proto obsahoval jen jednu neuronovou síť. Pro každou dvojici měrných profilů byl sestaven jeden model.



Obr. 61. Ukázka hydrogramu

Velkou výhodou modelu 2.0 oproti modelu 1 bylo, že při trénování nedocházelo k přetrénování neuronové sítě. Model dával výsledky, které byly stejné jako u nejlepších variant pro předchozí modely. Nevýhodami modelu byly delší čas na proces učení a počet vstupů, který byl roven maximální předpokládané hodnotě postupové doby ( $Mt$ ). Největší výhodou modelu je, že není třeba hledat hodnotu postupové doby, protože si ji model sám najde.



**Obr. 62.** Ukázka hydrogramu


Model dával stejné výsledky, jakých dosáhly nejlepší varianty předchozích modelů, a proto se mohou použít oba modely. Model 2.0 byl pro měrné stanice Dvorce – Ptáčov a Batelov-Ptáčov jednodušší, protože obsahoval jen jednu neuronovou síť na rozdíl od nejlepších variant předchozího modelu.

Ostatní výstupy pro model obsahující neuronové sítě 2.0 spolu se skripty pro tento model budou přiloženy na DVD.

## 9 ANALÝZA VÝSLEDKŮ A SROVNÁNÍ VÝSLEDKŮ


Posledním krokem byla analýza výsledků, ačkoliv toto téma bylo zmíněno u jednotlivých modelů. Stalo by se velmi roztříštěným a chybělo by zde přímé srovnání výstupů z nejlepších modelů obsahující neuronové sítě 1.0.

Následuje několik výstupů z modelů Batelov – Dvorce, jež obsahují povodňové události předpovězené oběma modely a z reálných dat. Není zde uveden koeficient determinace, protože je uveden u jednotlivých výstupů přiložených na DVD.




**Obr. 63.** Ukázka hydrogramu

Na grafech můžeme vidět, že oba modely dávají přibližně stejné výsledky. Při bližším zkoumání zjistíme, že model obsahující neuronové sítě má lepší výsledky kulminačních průtoků. Velkou výhodou regresního modelu je jeho jednoduchost, protože obsahuje jen jednu rovnici a výsledky jím předpovězené nejsou výrazně horší. Z důvodu uvedeného výše vyplývá, že je výrazně lepší využít regresní model 1.2 než model obsahující neuronové sítě.




**Obr. 64.** Ukázka hydrogramu




**Obr. 65.** Ukázka hydrogramu

Další ukázky náleží modelu Dvorce – Ptáčov, jenž má stejnou strukturu výstupu jako model předchozí.




**Obr. 66.** Ukázka hydrogramu



**Obr. 67.** Ukázka hydrogramu


Na grafech můžeme vidět, že oba modely dávají přibližně stejné výsledky. Vzhledem ke složitosti modelu obsahujícího neuronové sítě a problémům při tréninku bude výhodnější využít regresní model namísto modelu s neuronovými sítěmi, které nejsou určeny pro extrapolaci.

Poslední ukázky náleží modelu Dvorce – Ptáčov, jenž má stejnou strukturu výstupu jako první model.




**Obr. 68.** Ukázka hydrogramu

Na grafech lze vidět, že výsledky průtoků, jež oba modely předpověděly, jsou si velmi podobné. Hodnoty předpovězených kulminačních průtoků jsou lepší pro model obsahující neuronové sítě, avšak předpovědi z regresního modelu nedávají o mnoho horší výsledky než u druhého modelu, a proto je výhodnější využít regresní model. Důvodem je jeho jednoduchost oproti modelu obsahujícímu neuronové sítě.



**Obr. 69.** Ukázka hydrogramu



**Obr. 70.** Ukázka hydrogramu

## 9.1 ROZHODOVACÍ TABULKA PRO REGRESNÍ VZTAHY

Tab. 10. Regresní rovnice

Hydrologická událost	Regresní rovnice
<b>Měrný profil Batelov – Dvorce</b>	
Vzestupná větev	$y = -0.11154 + 3.8268x$ nebo $y = 0.030043 - 0.63978x + 5.9282x^2$
Sestupná větev	$y = -0.1499 + 5.2145x$ nebo $y = 0.019296 - 0.43256x + 6.2049x^2$
Vzestupná větev +8 hod	$y = -0.12925 + 4.4575x$ nebo $y = 0.012368 - 0.34671x + 5.3226x^2$
Sestupná větev +8 hod	$y = -0.15998 + 5.0888x$ nebo $y = 0.019566 - 0.44659x + 6.0931x^2$
<b>Měrný profil Dvorce – Ptáčov</b>	
Vzestupná větev	$y = -2.6249 + 3.0991x$
Sestupná větev	$y = 0.90737 + 2.1602x$
<b>Měrný profil Batelov - Ptáčov</b>	
Vzestupná větev	$y = 2.7654 + 8.6886x$
Sestupná větev	$y = -0.96768 + 11.6217x$

Výhodou regresních modelů oproti neuronovým sítím je schopnost extrapolace.



## 10 ZÁVĚR

Diplomová práce se zabývá nejen teoretickým popisem problémů a metod, ale i aplikací teoretických znalostí pro praktické využití. Pro sestavování modelu regresní analýzy i modelů obsahující neuronové sítě se vycházelo ze stejných dat. Celkový objem dat práce je natolik objemný, že na DVD byly uloženy jen základní data z nichž lze za pomoci uložených skriptů, vytvořit celý rozsah dat, která byla zapotřebí.

Nejdříve byly sestaveny modely regresní analýzy, pro které muselo být vytvořeno několik variant. Jednotlivé varianty musely být sestavovány, aby byla nalezena varianta schopná kvalitních předpovědí. Celkově byly pro každou dvojici měrných profilů sestaveny čtyři základní varianty s mnoha podvariantami. Podvarianty se lišily jen postupovou dobou události. Po zpracování velkého rozsahu výstupů byly nakonec vybrány nejlepší varianty.

Rovněž byly zpracovány modely obsahující neuronové sítě, které měly oproti předchozí variantě tu výhodu, že nebylo potřeba hledat a řešit regresní vztahy mezi jednotlivými profilem. Pro modely byly sestaveny čtyři základní varianty pro každou dvojici měrných profilů. Nejdříve se musela zvolit nejvhodnější struktura neuronové sítě. Ta byla stanovována pro různé hodnoty neuronů ve skryté vrstvě. Po nalezení vhodné struktury neuronové sítě bylo přikročeno k samotné tvorbě modelů. Stejně jako v případě regresních modelů i zde bylo sestaveno velké množství podvariant, které se lišily postupovou dobou.

Dalšími sestavovanými modely byly modely s neuronovou sítí 2.0. Zde byla nechána veškerá práce v hledání funkčních závislostí na modelu. Model obsahoval jen jednu neuronovou síť, ale matice vstupů obsahovala průtoky v horní měrné stanici pro všechny předpokládané varianty. Dosahoval stejných výsledků jako nejlepší varianty předchozích modelů. Jeho nevýhodou je potřeba zadávat vstupní průtok pro různé hodnoty postupové doby, a proto je model vhodný jen pro události s hodnotami okamžitých hodinových průtoků. V opačném případě by klesla přesnost modelu. Hlavní model pro neuronové sítě nebyl určen, protože oba předpovědní modely dávaly téměř stejné výsledky. Nakonec bylo rozhodnuto, že modely regresní analýzy měly dostatečnou předpovědní schopnost a byly upřednostněny před modely obsahující neuronové sítě. Hlavním důvodem bylo omezení neuronových sítí extrapolovat průtoky mimo tréninkovou oblast.

Pro tvorbu neuronových sítí byl použit Neural toolbox programu Matlab R2010a, který dokázal velmi dobře a s dostatečnou rychlostí tvořit neuronové sítě, a proto lze tento program doporučit pro tvorbu neuronových sítí.

Posledním bodem bylo sestavení empirických a teoretických čar překročení pro objemy povodňových událostí. Dále byly vypsány do tabulek hodnoty pro vybrané N-letosti.

Závěrem lze říci, že sestavené předpovědní modely mohou být použity pro řízení vodního díla Dalešice, které leží pod měrným profilem Ptáčov. Mimo modelů mohou být použity i empirické a teoretické čáry překročení, které mohou pomoci udělat si představu o objemu N-letých povodní.

## 11 POUŽITÁ LITERATURA

- [1] [http://cs.wikipedia.org/wiki/Jihlava\\_\(řeka\)](http://cs.wikipedia.org/wiki/Jihlava_(řeka))
- [2] STARÝ, M.: *Hydrologie*. Studijní opora pro kombinované studium. VUT FAST Brno, 2005
- [3] <http://www.chmi.cz/>
- [4] Hydrologické poměry ČR a Klimatický atlas ČR.
- [5] Produktová nápověda programu Matlab R2010a
- [6] KOZEL, Tomáš. *Vyhodnocení povodňových vln v horní části povodí řeky Jihlavy*. Brno, 2011. 108 s., 3 s. příl. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce prof. Ing. Miloš Starý, CSc..
- [7] Průběhy vodních stavů v profilu Batelov/Jihlava
- [8] Měrné křivky průtoků v profilu Dvorce/Jihlava a Ptáčov/Jihlava.
- [9] HIESBÖCKOVÁ, Tereza. *Předpovídání povodňových průtoků v měrných profilech Borovnice - Dalečín*. Brno, 2011. 107 s., 167 s. příl. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce prof. Ing. Miloš Starý, CSc..

## 12 SEZNAM OBRÁZKŮ

Obr. 2 Průměrná roční teplota .....	12
Obr. 3 Průměrný srážkový úhrn .....	12
Obr. 1 Měrné profily .....	12
Obr. 4 Umístění měrného profilu .....	14
Obr. 5 Příčný profil měrného profilu Batelov .....	15
Obr. 6 Foto stanice a měrného profilu Batelov .....	15
Obr. 7 Umístění měrného profilu .....	17
Obr. 8 Příčný profil měrného profilu Dvorce.....	18
Obr. 9 Foto měrné stanice a měrného profilu Dvorce.....	18
Obr. 10 Umístění měrného profilu .....	20
Obr. 11 Příčný profil měrného profilu Ptáčov.....	21
Obr. 12 Foto měrné stanice a měrného profilu Ptáčov.....	21
Obr. 13 Měrná křivka průtoku.....	23
Obr. 14 Ukázka čáry překročení objemů pro měrnou stanici Batelov .....	26
Obr. 15 Určení postupových dob průtoků [2] .....	28
Obr. 16 Nevhodný hydrogram pro postupovou dobu Dvorce - Ptáčov .....	29
Obr. 17 Ukázka vhodného hydrogramu .....	29
Obr. 18 Ukázka postupové doby Batelov – Dvorce.....	30
Obr. 19 Závislost postupové doby na průtoku $Q_h$ .....	30
Obr. 20 Závislost postupové doby na průtoku $Q_h$ .....	31
Obr. 21 Mezi proměnnými X a Y není žádná závislost .....	33
Obr. 22 Mezi proměnnými X a Y je funkční závislost .....	34
Obr. 23 Mezi proměnnými X a Y je pravděpodobnostní závislost.....	34
Obr. 24 Zobrazení metody nejmenších čtverců .....	35
Obr. 25 Měřený a modelovaný průtok .....	36
Obr. 26 Schéma 1 a schéma 2 .....	37
Obr. 27 Ukázka závislosti .....	40
Obr. 28 Ukázka hydrogramu pro model 1.2.....	42
Obr. 29 Ukázka hydrogramu pro model 1.2.....	42
Obr. 30 Ukázka hydrogramu pro model 1.2.....	43
Obr. 31 Ukázka hydrogramu .....	44
Obr. 32 Ukázka hydrogramu.....	45
Obr. 33 Ukázka hydrogramu .....	46

Obr. 34 Ukázka hydrogramu .....	46
Obr. 35 Ukázka hydrogramu .....	47
Obr. 36 Ukázka hydrogramu .....	47
Obr. 37 Biologický neuron.....	49
Obr. 38 Umělý neuron.....	49
Obr. 39 Neuronová síť.....	50
Obr. 40 Sigmoida $\beta = 0.25$ .....	50
Obr. 41 Ukázka neuronové sítě .....	52
Obr. 42 Neural toolbox programu Matlab R2010a .....	53
Obr. 43 Ukázka závislosti vytvořené neuronovou sítí .....	54
Obr. 44 Ukázka přetrénování neuronové sítě.....	55
Obr. 45 Ukázka druhotného přetrénování .....	56
Obr. 46 Ukázka předpovědi modelem Batelov – Dvorce varianta 1 .....	57
Obr. 47 Ukázka předpovědi varianty 1 .....	58
Obr. 48 Ukázka závislosti mezi horní a dolní stanicí.....	59
Obr. 49 Ukázka validace, testování a trénování.....	59
Obr. 50 Ukázka závislosti pro variantu 1 a pro postupovou dobu +4h.....	61
Obr. 51 Ukázka závislosti pro variantu 1.1 bez největší události pro časový posun +7h.....	62
Obr. 52 Ukázka hydrogramu varianta 1.1 .....	62
Obr. 53 Ukázka hydrogramu .....	63
Obr. 54 Ukázka závislosti pro variantu 1.1 a pro postupovou dobu +2h.....	65
Obr. 55 Ukázka hydrogramu pro variantu 1.1 .....	65
Obr. 56 Ukázka hydrogramu pro variantu 1.1 .....	66
Obr. 57 Ukázka hydrogramu .....	67
Obr. 58 Ukázka hydrogramu .....	67
Obr. 59 Ukázka hydrogramu .....	68
Obr. 60 Ukázka hydrogram .....	68
Obr. 61 Ukázka hydrogramu .....	69
Obr. 62 Ukázka hydrogramu .....	70
Obr. 63 Ukázka hydrogramu .....	71
Obr. 64 Ukázka hydrogramu .....	72
Obr. 65 Ukázka hydrogramu .....	72
Obr. 66 Ukázka hydrogramu .....	73
Obr. 67 Ukázka hydrogramu .....	73
Obr. 68 Ukázka hydrogramu .....	74

Obr. 69 Ukázka hydrogramu .....	75
Obr. 70 Ukázka hydrogramu .....	75
Obr. 71 Čáry překročení pro Johnsnovo rozdělení .....	131
Obr. 72 Rozdělení Johnsonovo .....	131
Obr. 73 Čáry překročení pro Johnsnovo rozdělení .....	132
Obr. 74 Rozdělení Johnsonovo .....	132
Obr. 75 Čáry překročení pro Johnsnovo rozdělení .....	133
Obr. 76 Rozdělení Johnsonov .....	133

## **13 SEZNAM TABULEK**

Tab. 1 Geografické údaje o vodoměrné stanici Batelov .....	13
Tab. 2 N-leté průtoky Batelov .....	13
Tabulka 3 Geografické údaje o vodoměrné stanici Dvorce .....	16
Tabulka 4 N-leté průtoky Dvorce.....	16
Tabulka 5 Geografické údaje o vodoměrné stanici Dvorce .....	19
Tabulka 6 N-leté průtoky Ptáčov .....	19
Tabulka 7 Objemy povodní pro měrný profil Batelov .....	26
Tabulka 8 Objemy povodní pro měrný profil Dvorce.....	26
Tabulka 9 Objemy povodní pro měrný profil Ptáčov .....	26
Tabulka 10 Regresní rovnice.....	76

## **14 SEZNAM PŘÍLOH**

**PŘÍLOHA 1 – HYDROGRAMY POVODNÍ PRO MODEL 1.2 A ZÁVISLOSTI B-D**

**PŘÍLOHA 2 – UKÁZKA M – FILE PRO MODEL 1.2**



**PŘÍLOHA 3 – TEORETICKÉ A EMPIRICKÉ ČÁRY PŘEKROČENÍ**


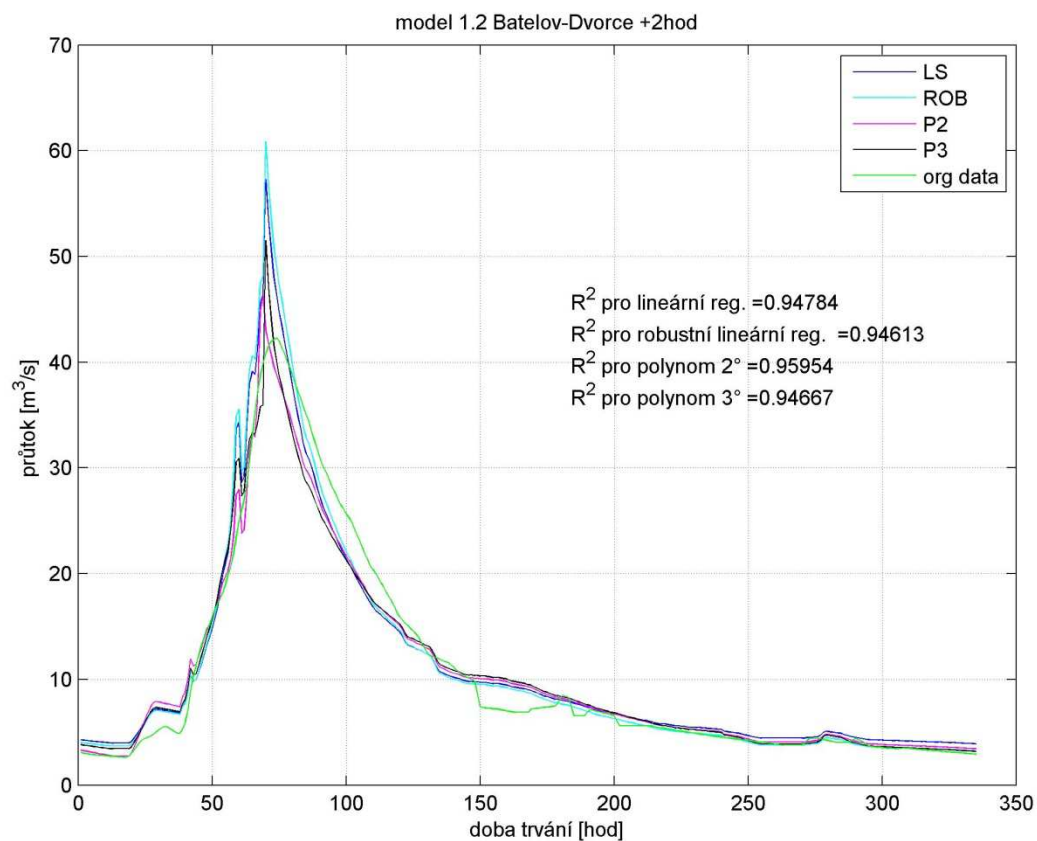
## 15 SEZNAM ZKRATEK A ZNAČEK



ČHMÚ	...	Český hydrometeorologický ústav
MKP	...	měrná křivka průtoků
$Q_a$	...	dlouhodobý průměrný roční průtok [ $\text{m}^3/\text{s}$ ]
$Q_N$	...	N-letý průtok [ $\text{m}^3/\text{s}$ ]
$Q, Q_i, X$	...	okamžitý hodinový průtok [ $\text{m}^3/\text{s}$ ]
$h, h_i$	...	vodní stav [cm]
$p$	...	pravděpodobnost překročení [-]
$N$	...	$N$ – letost
$e$	...	přirozený základ logaritmu
$\Delta t$	...	délka časového kroku sledované povodňové události
$I$	...	skoln hladiny v toku
$K$	...	koeficient tvaru koryta
$S$	...	délka říčního úseku
$c$	...	drsnost koryta
$\tau_i$	...	postupová doba [hod]
$t_{iQh}$	...	doba dotoku v horním profilu [hod]
$t_{iQd}$	...	doba dotoku v dolním profilu [hod]
$E$	...	celková chyba neuronové sítě
$Q_{t+\tau}^P$	...	Průtok v dolní stanici zvětšený o postupovou dobu [ $\text{m}^3/\text{s}$ ]
$\Delta Q_{t+\tau}$	...	přírusek průtoků z mezipovodí [ $\text{m}^3/\text{s}$ ]
$Q_t^Z$	...	Průtok v horní stanici [ $\text{m}^3/\text{s}$ ]
$\varphi$	...	minimum sumy součtu metody nejmenších čtverců
$Y_i^{\wedge}$	...	předpovídaný průtok [ $\text{m}^3/\text{s}$ ]
$Y_i$	...	měřený průtok [ $\text{m}^3/\text{s}$ ]
$R^2, R$	...	koeficient determinace
$t$	...	doba posunu [hod]
$H$	...	množina hran
$N$	...	množina vrcholů
B-D	...	Batelov - Dvorce
D-P	...	Dvorce - Ptáčov
B-P	...	Batelov - Ptáčov
$Mt$	...	maximální předpokládaná postupová doba [hod]







## **PŘÍLOHA 1**



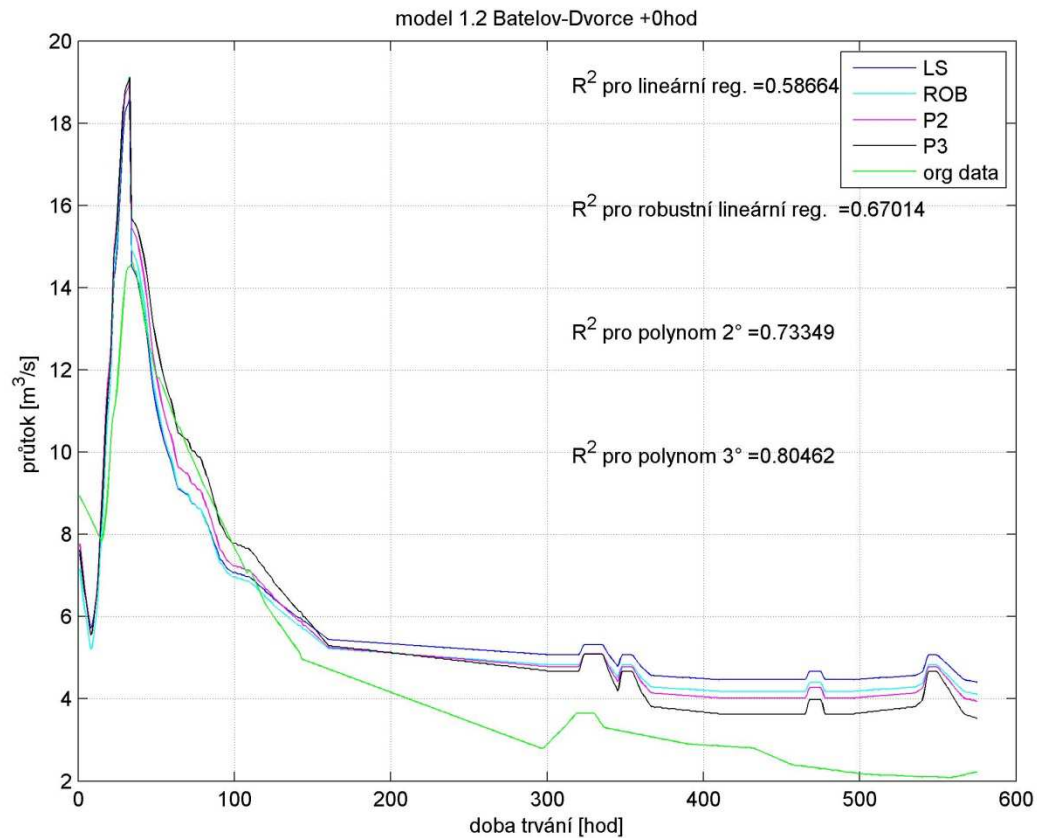



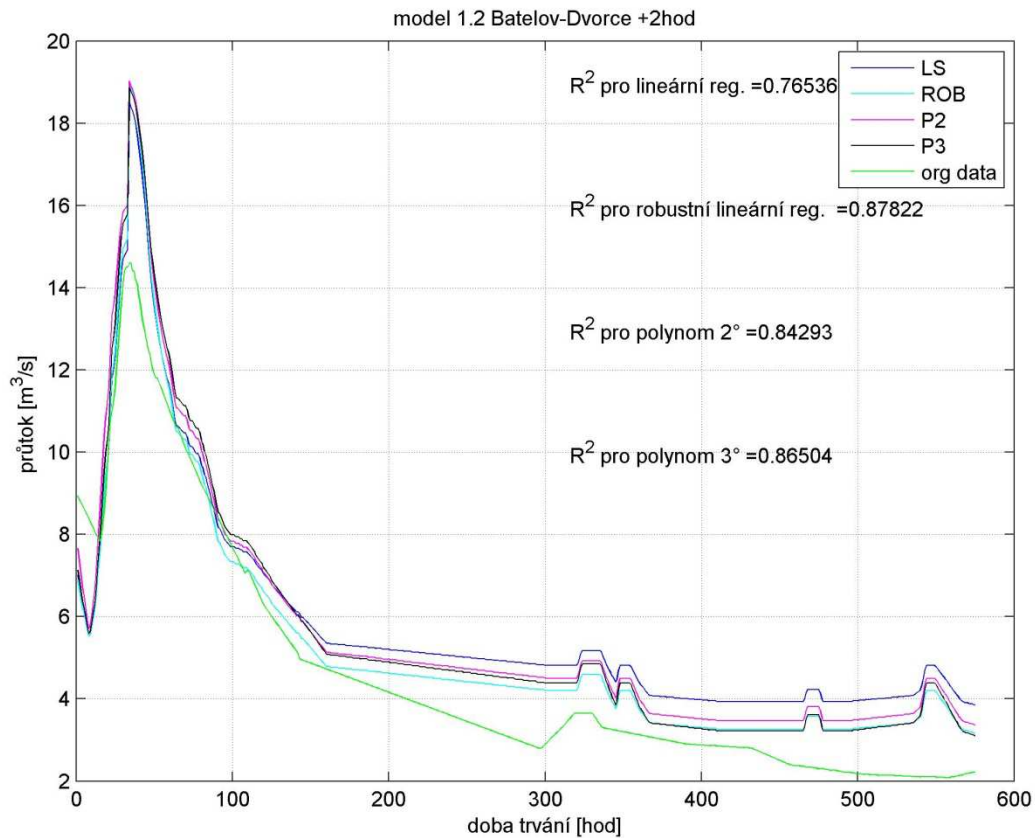
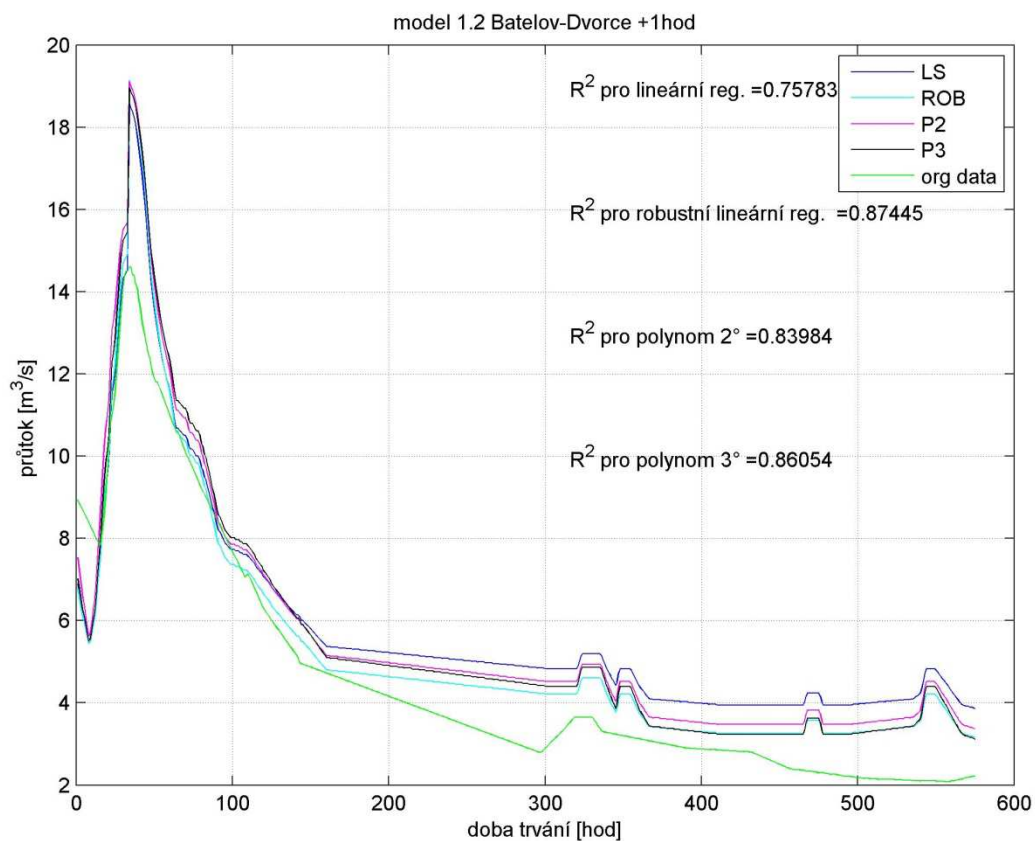




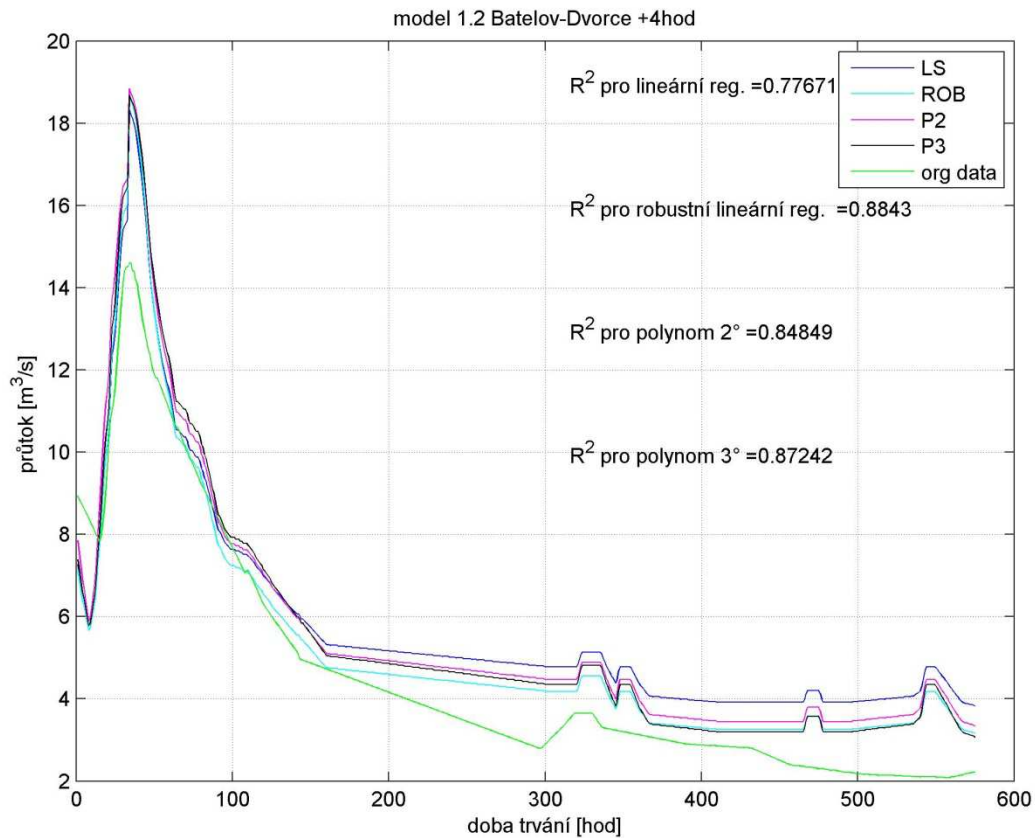
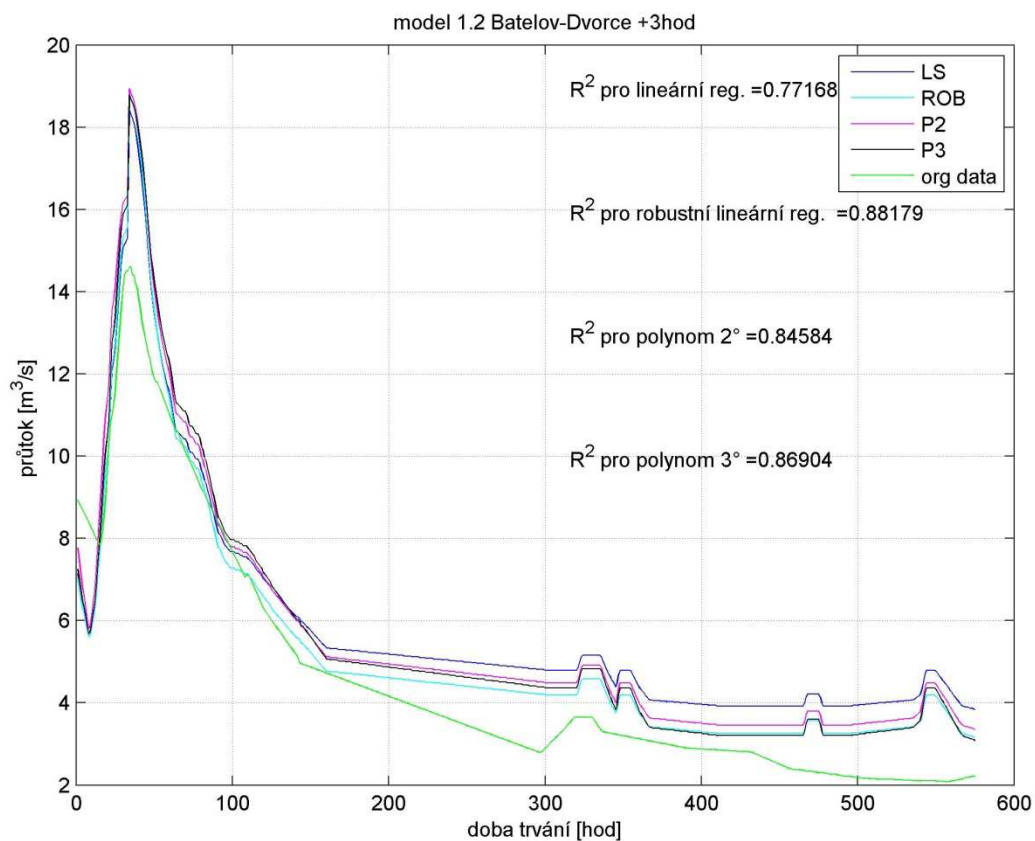



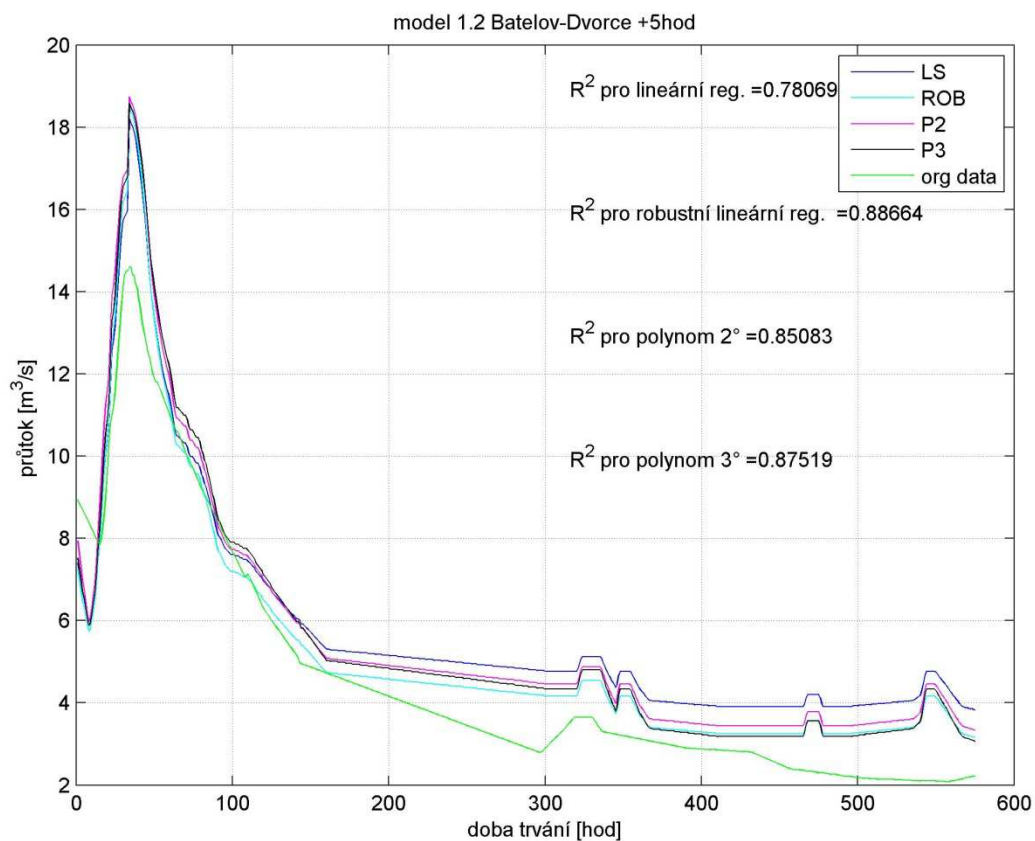


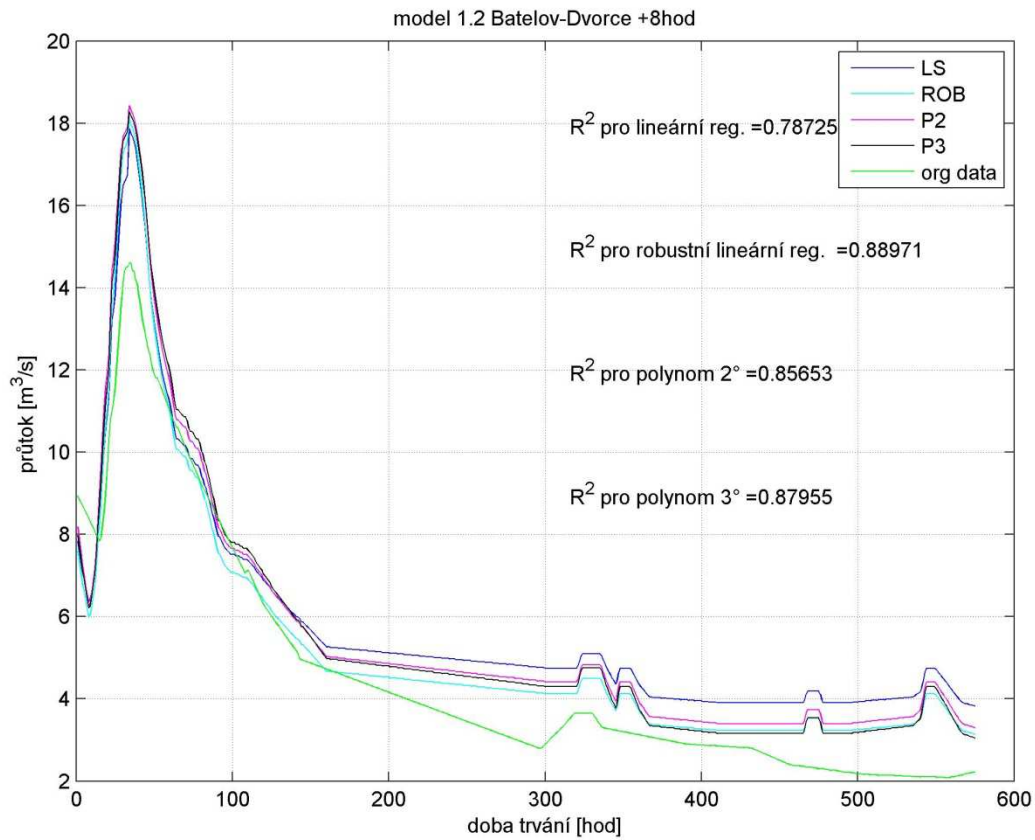



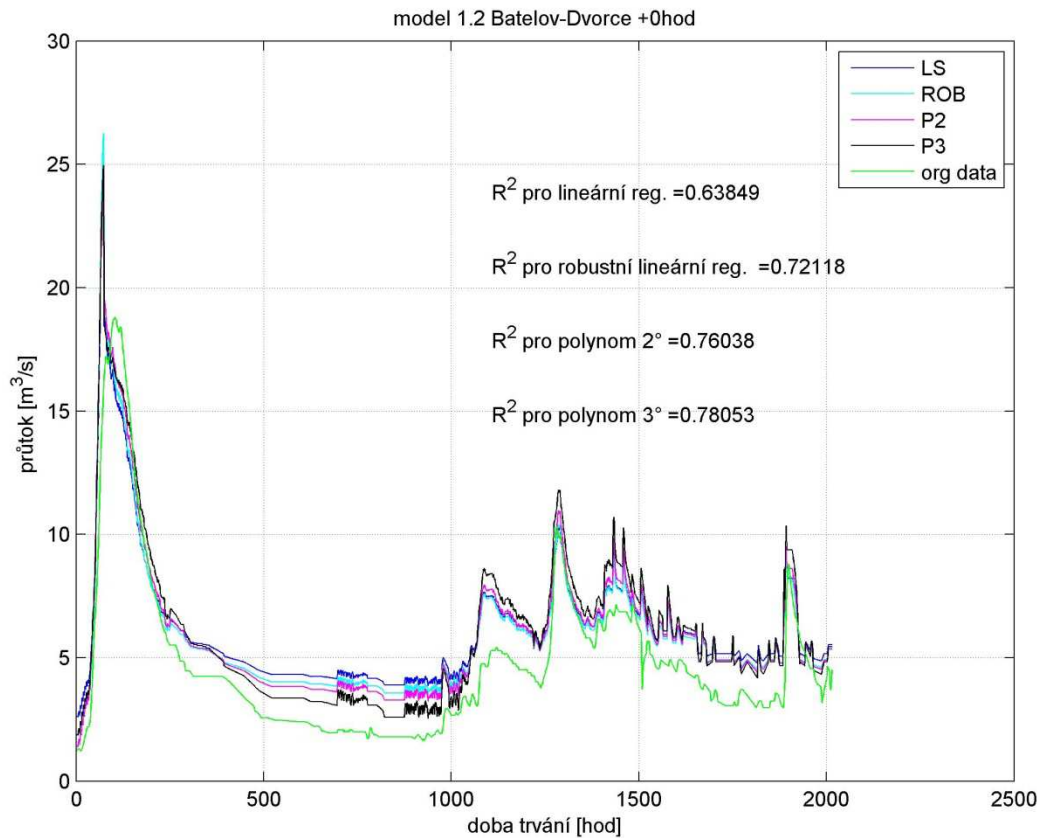
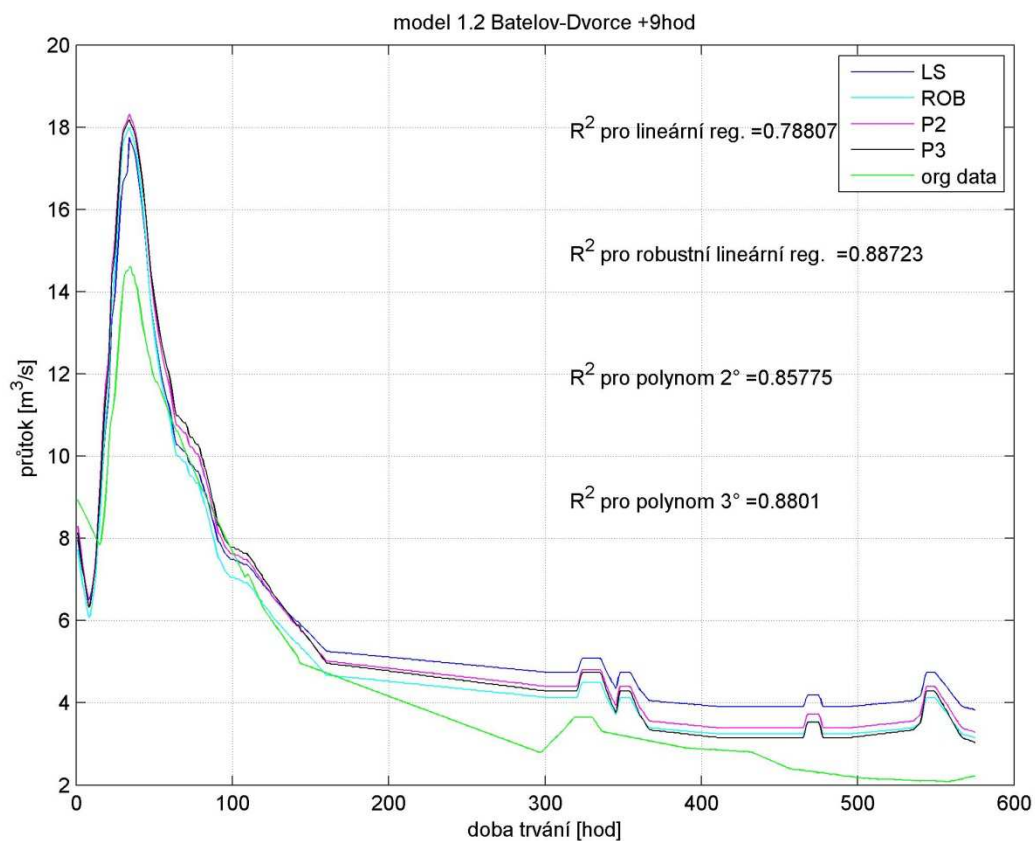


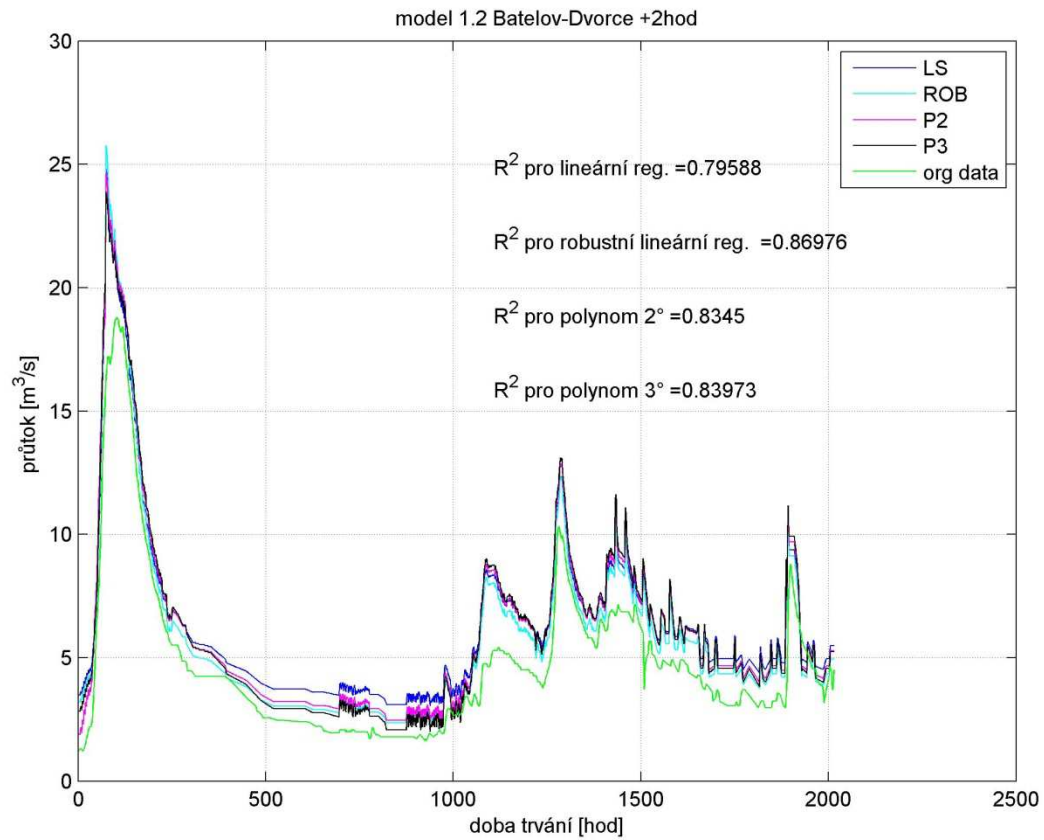





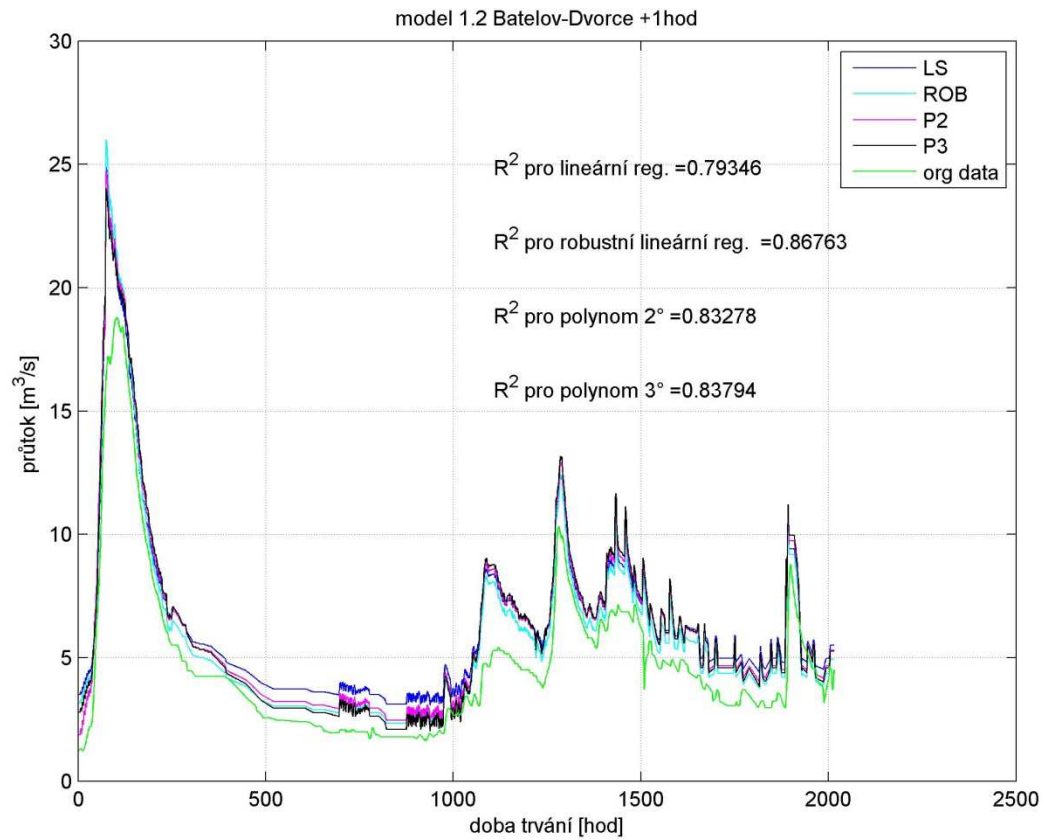



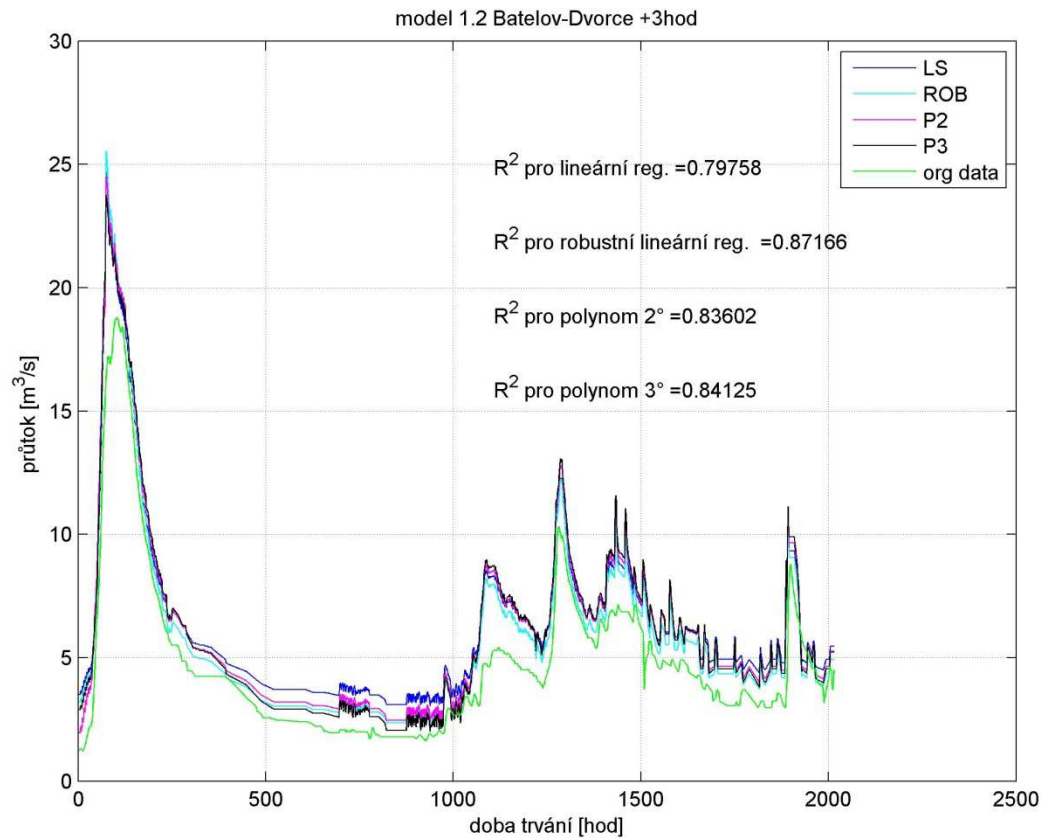
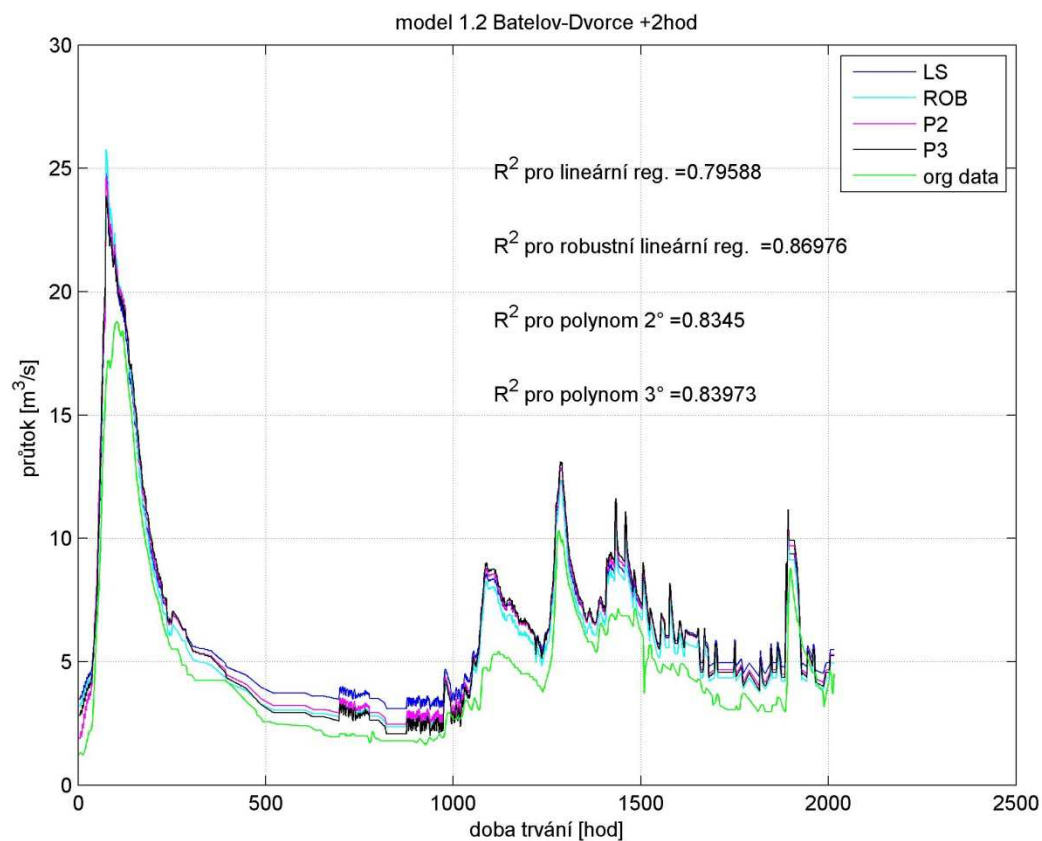


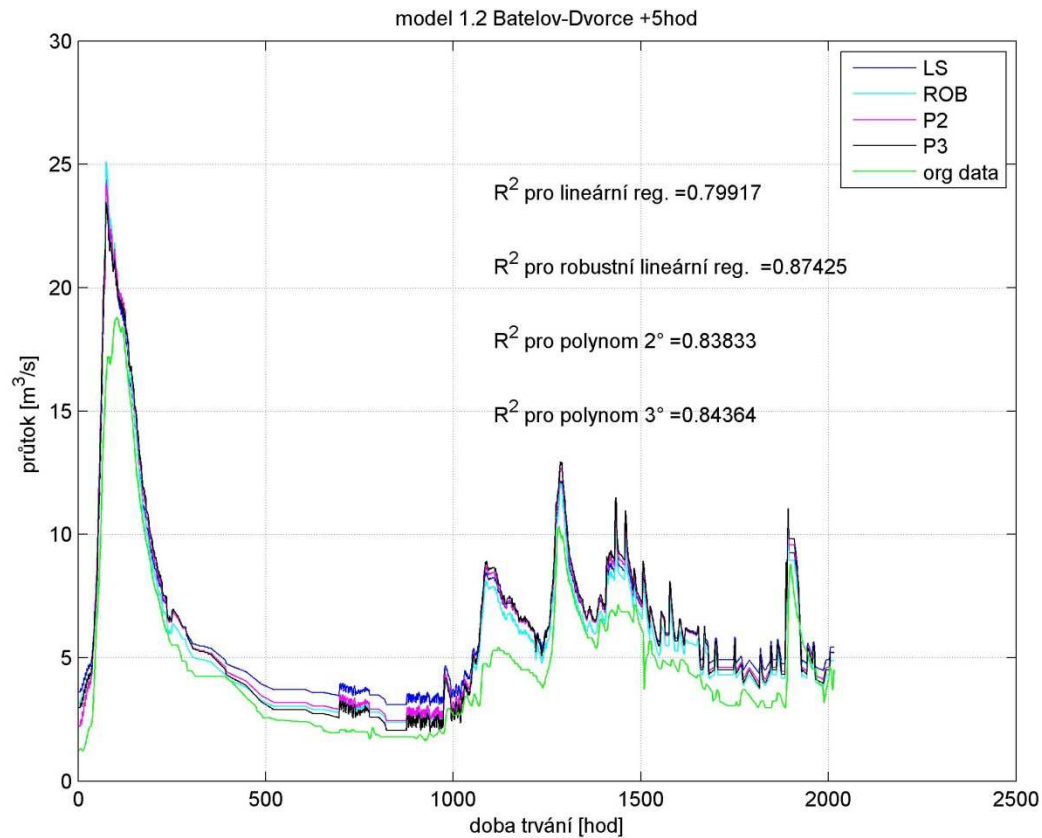





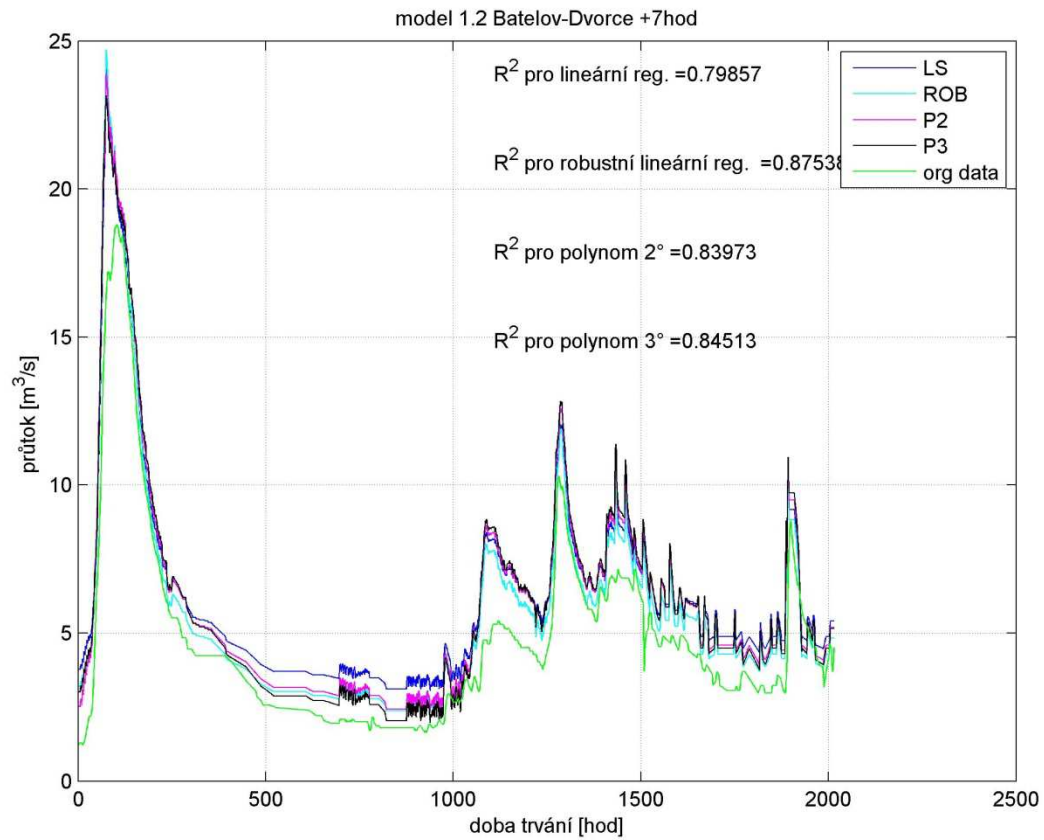



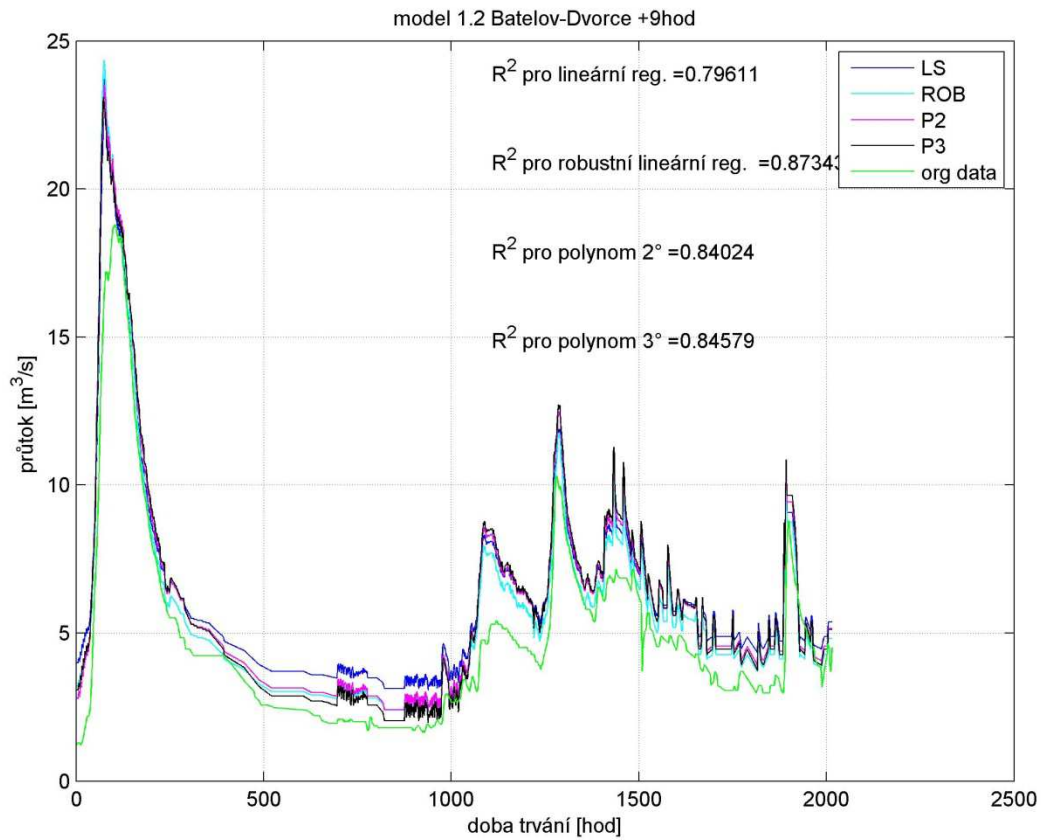





























































## **PŘÍLOHA 2**

## M – FILE

### Ukázka z regresního modelu 1.2 Batelov - Dvorce

```
numFiles = 26

for i=2:numFiles
    s = ['BD', '= R', int2str(i)];
    eval(s);
    [m n]=size (BD);
    akd=max(BD(:,1));
    B=BD(:,1);
    BB=BD(:,2);
    [r,c]=find(akd==B(:,1));
    rr=min(r);

    for p=1
        Bv=zeros(rr+p-1,2);
        Bs=zeros(m-rr-p+1,2);
        for k=1:rr+p-1
            Bv(k,:)=BD(k,:);
        end

        for j=rr+p:m
            Bs(j-rr-p+1,:)=BD(j,:);
        end

        s = ['Bs', int2str(i), 'h', int2str(p), '=Bs'];
        eval(s);
        name = ['Bs' int2str(i), 'h', int2str(p) '.mat'];
        eval(['save ', name]);
        s = ['Bv', int2str(i), 'h', int2str(p), '=Bv'];
        eval(s);
        name = ['Bv' int2str(i), 'h', int2str(p) '.mat'];
        eval(['save ', name]);
    end
end

numFiles = 26

for i=2:numFiles
    p=1;
    s = ['Vk', '= Bv', int2str(i), 'h', int2str(p)];
    eval(s);
    s = ['Sk', '= Bs', int2str(i), 'h', int2str(p)];
    eval(s);

    Yvk=Vk(:,2);
    Zvk=Vk(:,1);
    Ysk=Sk(:,2);
    Zsk=Sk(:,1);
    [n,m]=size(Vk);
    [nn,mm]=size(Sk);
```

```

Ysp=zeros(nn-11,1);Zsp=zeros(nn-11,1); Zvp=zeros(n,1);
Zvp=Zvk;

for pp=1:10
for k=1:nn-11

    Zsp(k,1)= Zsk(k,1);
    Ysp(k,1)=Ysk(k+pp-1,1);
end

Yvp2=zeros(pp,1);
    Yvp1=zeros(n-pp,1);

for k=1:n-pp
Yvp1(k,1)=Yvk(k+pp-1,1);
end
for k=1:pp
Yvp2(k,1)=Ysk(k+pp-1,1);
end

Yvp3=vertcat(Yvp1,Yvp2);
batt1=[Zvp Yvp3];
batt2=[Zsp Ysp];
s = ['Bss',int2str(i),'h',int2str(pp+1),'=batt1'];
eval(s);
name = ['Bss' int2str(i),'h',int2str(pp+1) '.mat'];
eval(['save ', name]);
s = ['Bvv',int2str(i),'h',int2str(pp+1),'=batt2'];
eval(s);
name = ['Bvv' int2str(i),'h',int2str(pp+1) '.mat'];
eval(['save ', name]);
end
end

YavBt0=vertcat(Bs2h1,Bs3h1,Bs4h1,Bs5h1,Bs6h1,Bs7h1,Bs8h1,Bs9h1,Bs10h1,Bs11h
1,Bs12h1,Bs13h1);
YavBtt0=vertcat(Bs14h1,Bs15h1,Bs16h1,Bs17h1,Bs18h1,Bs19h1,Bs20h1,Bs21h1,Bs2
2h1,Bs23h1,Bs24h1,Bs25h1,Bs26h1);
YavBttt0=vertcat(YavBt0,YavBtt0);
ZavBt0=(YavBttt0);

YavBt1=vertcat(Bss2h2,Bss3h2,Bss4h2,Bss5h2,Bss6h2,Bss7h2,Bss8h2,Bss9h2,Bss1
0h2,Bss11h2,Bss12h2,Bss13h2);
YavBtt1=vertcat(Bss14h2,Bss15h2,Bss16h2,Bss17h2,Bss18h2,Bss19h2,Bss20h2,Bss
21h2,Bss22h2,Bss23h2,Bss24h2,Bss25h2,Bss26h2);
YavBttt1=vertcat(YavBt1,YavBtt1);
ZavBt1=(YavBttt1);

```

```

YavBt2=vertcat(Bss2h3,Bss3h3,Bss4h3,Bss5h3,Bss6h3,Bss7h3,Bss8h3,Bss9h3,Bss1
0h3,Bss11h3,Bss12h3,Bss13h3);
YavBtt2=vertcat(Bss14h3,Bss15h3,Bss16h3,Bss17h3,Bss18h3,Bss19h3,Bss20h3,Bss
21h3,Bss22h3,Bss23h3,Bss24h3,Bss25h3,Bss26h3);
    YavBttt2=vertcat(YavBt2,YavBtt2);
    ZavBt2=(YavBttt2);

```

```

YavBt3=vertcat(Bss2h4,Bss3h4,Bss4h4,Bss5h4,Bss6h4,Bss7h4,Bss8h4,Bss9h4,Bss1
0h4,Bss11h4,Bss12h4,Bss13h4);
YavBtt3=vertcat(Bss14h4,Bss15h4,Bss16h4,Bss17h4,Bss18h4,Bss19h4,Bss20h4,Bss
21h4,Bss22h4,Bss23h4,Bss24h4,Bss25h4,Bss26h4);
    YavBttt3=vertcat(YavBt3,YavBtt3);
    ZavBt3=(YavBttt3);

```

```

YavBt4=vertcat(Bss2h5,Bss3h5,Bss4h5,Bss5h5,Bss6h5,Bss7h5,Bss8h5,Bss9h5,Bss1
0h5,Bss11h5,Bss12h5,Bss13h5);
YavBtt4=vertcat(Bss14h5,Bss15h5,Bss16h5,Bss17h5,Bss18h5,Bss19h5,Bss20h5,Bss
21h5,Bss22h5,Bss23h5,Bss24h5,Bss25h5,Bss26h5);
    YavBttt4=vertcat(YavBt4,YavBtt4);
    ZavBt4=(YavBttt4);

```

```

YavBt5=vertcat(Bss2h6,Bss3h6,Bss4h6,Bss5h6,Bss6h6,Bss7h6,Bss8h6,Bss9h6,Bss1
0h6,Bss11h6,Bss12h6,Bss13h6);
YavBtt5=vertcat(Bss14h6,Bss15h6,Bss16h6,Bss17h6,Bss18h6,Bss19h6,Bss20h6,Bss
21h6,Bss22h6,Bss23h6,Bss24h6,Bss25h6,Bss26h6);
    YavBttt5=vertcat(YavBt5,YavBtt5);
    ZavBt5=(YavBttt5);

```

```

YavBt6=vertcat(Bss2h7,Bss3h7,Bss4h7,Bss5h7,Bss6h7,Bss7h7,Bss8h7,Bss9h7,Bss1
0h7,Bss11h7,Bss12h7,Bss13h7);
YavBtt6=vertcat(Bss14h7,Bss15h7,Bss16h7,Bss17h7,Bss18h7,Bss19h7,Bss20h7,Bss
21h7,Bss22h7,Bss23h7,Bss24h7,Bss25h7,Bss26h7);
    YavBttt6=vertcat(YavBt6,YavBtt6);
    ZavBt6=(YavBttt6);

```

```

YavBt7=vertcat(Bss2h8,Bss3h8,Bss4h8,Bss5h8,Bss6h8,Bss7h8,Bss8h8,Bss9h8,Bss1
0h8,Bss11h8,Bss12h8,Bss13h8);
YavBtt7=vertcat(Bss14h8,Bss15h8,Bss16h8,Bss17h8,Bss18h8,Bss19h8,Bss20h8,Bss
21h8,Bss22h8,Bss23h8,Bss24h8,Bss25h8,Bss26h8);
    YavBttt7=vertcat(YavBt7,YavBtt7);
    ZavBt7=(YavBttt7);

```



```

YavBt8=vertcat(Bss2h9,Bss3h9,Bss4h9,Bss5h9,Bss6h9,Bss7h9,Bss8h9,Bss9h9,Bss1
0h9,Bss11h9,Bss12h9,Bss13h9);
YavBtt8=vertcat(Bss14h9,Bss15h9,Bss16h9,Bss17h9,Bss18h9,Bss19h9,Bss20h9,Bss
21h9,Bss22h9,Bss23h9,Bss24h9,Bss25h9,Bss26h9);
    YavBttt8=vertcat(YavBt8,YavBtt8);
    ZavBt8=(YavBttt8);

```

```

YavBt9=vertcat(Bss2h10,Bss3h10,Bss4h10,Bss5h10,Bss6h10,Bss7h10,Bss8h10,Bss9
h10,Bss10h10,Bss11h10,Bss12h10,Bss13h10);
YavBtt9=vertcat(Bss14h10,Bss15h10,Bss16h10,Bss17h10,Bss18h10,Bss19h10,Bss20
h10,Bss21h10,Bss22h10,Bss23h10,Bss24h10,Bss25h10,Bss26h10);
    YavBttt9=vertcat(YavBt9,YavBtt9);
    ZavBt9=(YavBttt9);

```

```

for jj=1:10
    s = [ 'ZavBtg',int2str(jj),'=ZavBt',int2str(jj-1)];
    eval(s);
    name = [ 'ZavBtg' int2str(jj) '.mat'];
    eval([ 'save ', name]);

```

```

end

```

```

YavBw0=vertcat(Bv2h1,Bv3h1,Bv4h1,Bv5h1,Bv6h1,Bv7h1,Bv8h1,Bv9h1,Bv10h1,Bv11h
1,Bv12h1,Bv13h1);
YavBww0=vertcat(Bv14h1,Bv15h1,Bv16h1,Bv17h1,Bv18h1,Bv19h1,Bv20h1,Bv21h1,Bv2
2h1,Bv23h1,Bv24h1,Bv25h1,Bv26h1);
    YavBwwt0=vertcat(YavBw0,YavBww0);
    ZavBw0=(YavBwwt0);

```

```

YavBw1=vertcat(Bvv2h2,Bvv3h2,Bvv4h2,Bvv5h2,Bvv6h2,Bvv7h2,Bvv8h2,Bvv9h2,Bvv1
0h2,Bvv11h2,Bvv12h2,Bvv13h2);
YavBww1=vertcat(Bvv14h2,Bvv15h2,Bvv16h2,Bvv17h2,Bvv18h2,Bvv19h2,Bvv20h2,Bvv
21h2,Bvv22h2,Bvv23h2,Bvv24h2,Bvv25h2,Bvv26h2);
    YavBwwt1=vertcat(YavBw1,YavBww1);
    ZavBw1=(YavBwwt1);

```

```

YavBw2=vertcat(Bvv2h3,Bvv3h3,Bvv4h3,Bvv5h3,Bvv6h3,Bvv7h3,Bvv8h3,Bvv9h3,Bvv1
0h3,Bvv11h3,Bvv12h3,Bvv13h3);
YavBww2=vertcat(Bvv14h3,Bvv15h3,Bvv16h3,Bvv17h3,Bvv18h3,Bvv19h3,Bvv20h3,Bvv
21h3,Bvv22h3,Bvv23h3,Bvv24h3,Bvv25h3,Bvv26h3);
    YavBwwt2=vertcat(YavBw2,YavBww2);
    ZavBw2=(YavBwwt2);

```

```

YavBw3=vertcat(Bvv2h4,Bvv3h4,Bvv4h4,Bvv5h4,Bvv6h4,Bvv7h4,Bvv8h4,Bvv9h4,Bvv1
0h4,Bvv11h4,Bvv12h4,Bvv13h4);

```

```

YavBww3=vertcat(Bvv14h4,Bvv15h4,Bvv16h4,Bvv17h4,Bvv18h4,Bvv19h4,Bvv20h4,Bvv
21h4,Bvv22h4,Bvv23h4,Bvv24h4,Bvv25h4,Bvv26h4);
YavBwwt3=vertcat(YavBw3,YavBww3);
ZavBw3=(YavBwwt3);

YavBw4=vertcat(Bvv2h5,Bvv3h5,Bvv4h5,Bvv5h5,Bvv6h5,Bvv7h5,Bvv8h5,Bvv9h5,Bvv1
0h5,Bvv11h5,Bvv12h5,Bvv13h5);
YavBww4=vertcat(Bvv14h5,Bvv15h5,Bvv16h5,Bvv17h5,Bvv18h5,Bvv19h5,Bvv20h5,Bvv
21h5,Bvv22h5,Bvv23h5,Bvv24h5,Bvv25h5,Bvv26h5);
YavBwwt4=vertcat(YavBw4,YavBww4);
ZavBw4=(YavBwwt4);

YavBw5=vertcat(Bvv2h6,Bvv3h6,Bvv4h6,Bvv5h6,Bvv6h6,Bvv7h6,Bvv8h6,Bvv9h6,Bvv1
0h6,Bvv11h6,Bvv12h6,Bvv13h6);
YavBww5=vertcat(Bvv14h6,Bvv15h6,Bvv16h6,Bvv17h6,Bvv18h6,Bvv19h6,Bvv20h6,Bvv
21h6,Bvv22h6,Bvv23h6,Bvv24h6,Bvv25h6,Bvv26h6);
YavBwwt5=vertcat(YavBw5,YavBww5);
ZavBw5=(YavBwwt5);

YavBw6=vertcat(Bvv2h7,Bvv3h7,Bvv4h7,Bvv5h7,Bvv6h7,Bvv7h7,Bvv8h7,Bvv9h7,Bvv1
0h7,Bvv11h7,Bvv12h7,Bvv13h7);
YavBww6=vertcat(Bvv14h7,Bvv15h7,Bvv16h7,Bvv17h7,Bvv18h7,Bvv19h7,Bvv20h7,Bvv
21h7,Bvv22h7,Bvv23h7,Bvv24h7,Bvv25h7,Bvv26h7);
YavBwwt6=vertcat(YavBw6,YavBww6);
ZavBw6=(YavBwwt6);

YavBw7=vertcat(Bvv2h8,Bvv3h8,Bvv4h8,Bvv5h8,Bvv6h8,Bvv7h8,Bvv8h8,Bvv9h8,Bvv1
0h8,Bvv11h8,Bvv12h8,Bvv13h8);
YavBww7=vertcat(Bvv14h8,Bvv15h8,Bvv16h8,Bvv17h8,Bvv18h8,Bvv19h8,Bvv20h8,Bvv
21h8,Bvv22h8,Bvv23h8,Bvv24h8,Bvv25h8,Bvv26h8);
YavBwwt7=vertcat(YavBw7,YavBww7);
ZavBw7=(YavBwwt7);

YavBw8=vertcat(Bvv2h9,Bvv3h9,Bvv4h9,Bvv5h9,Bvv6h9,Bvv7h9,Bvv8h9,Bvv9h9,Bvv1
0h9,Bvv11h9,Bvv12h9,Bvv13h9);
YavBww8=vertcat(Bvv14h9,Bvv15h9,Bvv16h9,Bvv17h9,Bvv18h9,Bvv19h9,Bvv20h9,Bvv
21h9,Bvv22h9,Bvv23h9,Bvv24h9,Bvv25h9,Bvv26h9);
YavBwwt8=vertcat(YavBw8,YavBww8);
ZavBw8=(YavBwwt8);

YavBw9=vertcat(Bvv2h10,Bvv3h10,Bvv4h10,Bvv5h10,Bvv6h10,Bvv7h10,Bvv8h10,Bvv9
h10,Bvv10h10,Bvv11h10,Bvv12h10,Bvv13h10);
YavBww9=vertcat(Bvv14h10,Bvv15h10,Bvv16h10,Bvv17h10,Bvv18h10,Bvv19h10,Bvv20
h10,Bvv21h10,Bvv22h10,Bvv23h10,Bvv24h10,Bvv25h10,Bvv26h10);
YavBwwt9=vertcat(YavBw9,YavBww9);
ZavBw9=(YavBwwt9);

```

```

for jj=1:10
    s = ['ZavBwg',int2str(jj),'=ZavBw',int2str(jj-1)];
    eval(s);
    name = ['ZavBwg' int2str(jj) '.mat'];
    eval(['save ', name]);

end

cas=10;
for i=1:cas
    s = ['P', '= ZavBtg',int2str(i)];
    eval(s);
    x=P(:,1);y=P(:,2);
    [v,vv]=size(y);
    gbls0 = regress(y,[ones(v,1) x]);
    gbrob0 = robustfit(x,y);
    gpp0 = polyfit(x,y,2);
    gpp00 = polyfit(x,y,3);

    PP=zeros(v,1);
    P=zeros(v,1);
    R=zeros(v,1);
    L=zeros(v,1);

    XXX=x;
    for kk=1:v
        PP(kk)=(gpp0(3)+gpp0(2)*XXX(kk)+gpp0(1)*XXX(kk)^2);
        P(kk)=(gpp00(4)+gpp00(3)*XXX(kk)+gpp00(2)*XXX(kk)^2+gpp00(1)*XXX(kk)^3);
        R(kk)=(gbrob0(1)+gbrob0(2)*XXX(kk));
        L(kk)=(gbls0(1)+gbls0(2)*XXX(kk));
    end

    Yp=mean(y);
    [ml mp]=size (x);
    RrPp1=zeros(ml,1);
    RrPp2=zeros(ml,1);
    RrP1=zeros(ml,1);
    RrP2=zeros(ml,1);
    RrL1=zeros(ml,1);
    RrL2=zeros(ml,1);
    RrR1=zeros(ml,1);
    RrR2=zeros(ml,1);
    for c=1:ml-1
        RrPp1(c,1)=(PP(c,1)-Y(c,1)).^2;
        RrPp2(c,1)=(PP(c,1)-Yp(1,1)).^2;
        RrP1(c,1)=(P(c,1)-Y(c,1)).^2;
        RrP2(c,1)=(P(c,1)-Yp(1,1)).^2;
        RrL1(c,1)=(L(c,1)-Y(c,1)).^2;
        RrL2(c,1)=(L(c,1)-Yp(1,1)).^2;
        RrR1(c,1)=(R(c,1)-Y(c,1)).^2;
        RrR2(c,1)=(R(c,1)-Yp(1,1)).^2;
    end
end

```

```

RrPp=1-(sum(RrPp1)/sum(RrPp2));
RrP=1-(sum(RrP1)/sum(RrP2));
RrL=1-(sum(RrL1)/sum(RrL2));
RrR=1-(sum(RrR1)/sum(RrR2));
Rrr=vertcat(RrL,RrR,RrP,RrPp);
pl=max(x);
pll=max(y);
xx=0.3:pl;

h2=figure
axis([-Inf,Inf,0,Inf])
scatter(x,y,'filled'); grid on; hold on
ylabel('Dvorce Q [m^3/s]')
xlabel('Batelov Q [m^3/s]')
plot(xx,gbls0(1)+gbls0(2)*xx,'r','LineWidth',2);
plot(xx,gbls0(1)+gbls0(2)*xx,'c','LineWidth',2);
plot(xx,gpp0(3)+gpp0(2)*xx+gpp0(1)*xx.^2,'m','LineWidth',2);
plot(xx,gpp0(4)+gpp0(3)*xx+gpp0(2)*xx.^2+gpp0(1)*xx.^3,'k','LineWidth',
2);

imaxx=round(max(L)+2);
imax=round(1);
text(imax,imaxx,[' Robustní lineární závislost
y=',num2str(gbls0(1)),'+',num2str(gbls0(2)),'*x, hodnota R^2 =
',num2str(RrR(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(L)-1);
imax=round(1);
text(imax,imaxx,[' Lineární závislost
y=',num2str(gbls0(1)),'+',num2str(gbls0(2)),'*x, hodnota R^2 =
',num2str(RrL(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(L)-4);
imax=round(1);
text(imax,imaxx,['Závislost polynom 2°
y=',num2str(gpp0(1)),'+',num2str(gpp0(2)),'*x, hodnota R^2 =
',num2str(RrP(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(L)-7);
imax=round(1);
text(imax,imaxx,['Závislost polynom 3°
y=',num2str(gpp0(1)),num2str(gpp0(2)),'*x +',num2str(gpp0(3)),'*x^{2},
hodnota R^{2} = ',num2str(RrPp(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
title(['Závislosti Modelu 1.2 pro vzestupnou větev Batelov-Dvorce
+',num2str(i-1),'hod'])
legend('Data','Ordinary Least Squares','Robust Regression','Polynom
2°','Polynom 3°','Location','SouthEast')
hold off
print -djpeg -r300

```

```

        s = ['gbls0',int2str(i),'=gbls0'];
eval(s);
        name = ['gbls0' int2str(i) '.mat'];
eval(['save ', name]);

        s = ['gbrob0',int2str(i),'=gbrob0'];
eval(s);
        name = ['gbrob0' int2str(i) '.mat'];
eval(['save ', name]);

        s = ['gpp0',int2str(i),'=gpp0'];
eval(s);
        name = ['gpp0' int2str(i) '.mat'];
eval(['save ', name]);

        s = ['gpp00',int2str(i),'=gpp00'];
eval(s);
        name = ['gpp00' int2str(i) '.mat'];
eval(['save ', name]);
end

```

```

cas=10
for i=1:cas
    s = ['Pt', '= ZavBwg',int2str(i)];
    eval(s);
    x=Pt(:,1);y=Pt(:,2);
    [v,vv]=size(y);
    wbls0 = regress(y,[ones(v,1) x]);
    wbrob0 = robustfit(x,y);
    wpp0 = polyfit(x,y,2);
    wpp00 = polyfit(x,y,3);

    PP=zeros(v,1);
    P=zeros(v,1);
    R=zeros(v,1);
    L=zeros(v,1);

    XXX=x;
    for kk=1:v
        PP(kk)=(wpp0(3)+wpp0(2)*XXX(kk)+wpp0(1)*XXX(kk)^2);
        P(kk)=(wpp00(4)+wpp00(3)*XXX(kk)+wpp00(2)*XXX(kk)^2+wpp00(1)*XXX(kk)^3);
        R(kk)=(wbrob0(1)+wbrob0(2)*XXX(kk));
        L(kk)=(wbls0(1)+wbls0(2)*XXX(kk));
    end

    Yp=mean(y);
    [m1 mp]=size (x);
    RrPp1=zeros(m1,1);
    RrPp2=zeros(m1,1);
    RrP1=zeros(m1,1);
    RrP2=zeros(m1,1);
    RrL1=zeros(m1,1);
    RrL2=zeros(m1,1);
    RrR1=zeros(m1,1);

```

```

RrR2=zeros(m1,1);
for c=1:m1-1
RrPp1(c,1)=(PP(c,1)-Y(c,1)).^2;
RrPp2(c,1)=(PP(c,1)-Yp(1,1)).^2;
RrP1(c,1)=(P(c,1)-Y(c,1)).^2;
RrP2(c,1)=(P(c,1)-Yp(1,1)).^2;
RrL1(c,1)=(L(c,1)-Y(c,1)).^2;
RrL2(c,1)=(L(c,1)-Yp(1,1)).^2;
RrR1(c,1)=(R(c,1)-Y(c,1)).^2;
RrR2(c,1)=(R(c,1)-Yp(1,1)).^2;
end

RrPp=1-(sum(RrPp1)/sum(RrPp2));
RrP=1-(sum(RrP1)/sum(RrP2));
RrL=1-(sum(RrL1)/sum(RrL2));
RrR=1-(sum(RrR1)/sum(RrR2));
Rrr=vertcat(RrL,RrR,RrP,RrPp);
pl=max(x);
pll=max(y);
xx=0.3:pl;

h3=figure
axis([-Inf,Inf,0,Inf])
scatter(x,y,'filled'); grid on; hold on
ylabel('Dvorce Q [m^3/s]')
xlabel('Batelov Q [m^3/s]')
plot(xx,wbls0(1)+wbls0(2)*xx,'r','LineWidth',2);
plot(xx,wbrob0(1)+wbrob0(2)*xx,'c','LineWidth',2);
plot(xx,wpp0(3)+wpp0(2)*xx+wpp0(1)*xx.^2,'m','LineWidth',2);
plot(xx,wpp0(4)+wpp0(3)*xx+wpp0(2)*xx.^2+wpp0(1)*xx.^3,'k','LineWidth',
2);

imaxx=round(max(L)+2);
imax=round(1);
text(imax,imaxx,[' Robustní lineární závislost
y=',num2str(wbrob0(1)),'+',num2str(wbrob0(2)),'*x, hodnota R^2 =
',num2str(RrR(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(L)-1);
imax=round(1);
text(imax,imaxx,[' Lineární závislost
y=',num2str(wbls0(1)),'+',num2str(wbls0(2)),'*x, hodnota R^2 =
',num2str(RrL(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(L)-4);
imax=round(1);
text(imax,imaxx,['Závislost polynom 2°
y=',num2str(wpp0(1)),'+',num2str(wpp0(2)),'*x, hodnota R^2 =
',num2str(RrP(1,1))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(L)-7);
imax=round(1);

```

```

text(imax,imaxx,['Závislost polynom 3°
y=',num2str(wpp00(1)),num2str(wpp00(2)), '*x +',num2str(wpp00(3)), '*x^{2},
hodnota R^{2} = ',num2str(RrPp(1,1))],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
title(['Závislosti Modelu 1.2 pro sestupnou větev Batelov-Dvorce
+',num2str(i-1),'hod'])
legend('Data','Ordinary Least Squares','Robust Regression','Polynom
2°','Polynom 3°','Location','SouthEast')
hold off
print -djpeg -r300

```

```

    s = ['wbls0',int2str(i),'=wbls0'];
eval(s);
    name = ['wbls0' int2str(i) '.mat'];
eval(['save ', name]);

    s = ['wbrob0',int2str(i),'=wbrob0'];
eval(s);
    name = ['wbrob0' int2str(i) '.mat'];
eval(['save ', name]);

```

```

    s = ['wpp0',int2str(i),'=wpp0'];
eval(s);
    name = ['wpp0' int2str(i) '.mat'];
eval(['save ', name]);

```

```

    s = ['wpp00',int2str(i),'=wpp00'];
eval(s);
    name = ['wpp00' int2str(i) '.mat'];
eval(['save ', name]);

```

end

```

%R=26
cas=10;
numFiles = 2;

```

```

for u=2:numFiles
    for p=1:cas
        s = ['Q', ' = R',int2str(u)];
eval(s);
        s = ['Qs', ' = Bs',int2str(u) , 'h1'];
eval(s);
        s = ['Qw', ' = Bv',int2str(u) , 'h1'];
eval(s);
XX=(Qw(:,1));
XXX=(Qs(:,1));
X=(Q(:,1));
Y=(Q(:,2));
[ww kw]=size(Qw);

```

```

[www kww]=size(Qs);
    s = ['gpp0','=gpp0',int2str(p)];
eval(s);
    s = ['gpp00','=gpp00',int2str(p)];
eval(s);
    s = ['gbrob0','=gbrob0',int2str(p)];
eval(s);
    s = ['gbls0','=gbls0',int2str(p)];
eval(s);
    Py0=zeros(ww,1);
    Ly0=zeros(ww,1);
    Ry0=zeros(ww,1);
    Ppy0=zeros(ww,1);
    for kk=1:ww
        Py0(kk)=(gpp0(3)+gpp0(2)*XX(kk)+gpp0(1)*XX(kk)^2);
        Ppy0(kk)=(gpp00(4)+gpp00(3)*XX(kk)+gpp00(2)*XX(kk)^2+gpp00(1)*XX(kk)^3);
        Ry0(kk)=(gbrob0(1)+gbrob0(2)*XX(kk));
        Ly0(kk)=(gbls0(1)+gbls0(2)*XX(kk));
    end

    s = ['wpp0','=wpp0',int2str(p)];
eval(s);
    s = ['wpp00','=wpp00',int2str(p)];
eval(s);
    s = ['wbrob0','=wbrob0',int2str(p)];
eval(s);
    s = ['wbls0','=wbls0',int2str(p)];
eval(s);

    ppy0=zeros(www,1);
    PPy0=zeros(www,1);
    Rry0=zeros(www,1);
    Lly0=zeros(www,1);

    for kk=1:www
        ppy0(kk)=(wpp0(3)+wpp0(2)*XXX(kk)+wpp0(1)*XXX(kk)^2);
        PPy0(kk)=(wpp00(4)+wpp00(3)*XXX(kk)+wpp00(2)*XXX(kk)^2+wpp00(1)*XXX(kk)^3);
        Rry0(kk)=(wbrob0(1)+wbrob0(2)*XXX(kk));
        Lly0(kk)=(wbls0(1)+wbls0(2)*XXX(kk));
    end
    Pp=vertcat(Py0,PPy0);
    P=vertcat(Ppy0,ppy0);
    L=vertcat(Ly0,Lly0);
    R=vertcat(Ry0,Rry0);
    Yp=mean(Y);
    [ml mp]=size (Y);
    RrPp1=zeros(ml,1);
    RrPp2=zeros(ml,1);
    RrP1=zeros(ml,1);
    RrP2=zeros(ml,1);
    RrL1=zeros(ml,1);
    RrL2=zeros(ml,1);
    RrR1=zeros(ml,1);
    RrR2=zeros(ml,1);
    for c=1:ml

```



```

RrPp1(c,1)=(Pp(c,1)-Y(c,1)).^2;
RrPp2(c,1)=(Pp(c,1)-Yp(1,1)).^2;
RrP1(c,1)=(P(c,1)-Y(c,1)).^2;
RrP2(c,1)=(P(c,1)-Yp(1,1)).^2;
RrL1(c,1)=(L(c,1)-Y(c,1)).^2;
RrL2(c,1)=(L(c,1)-Yp(1,1)).^2;
RrR1(c,1)=(R(c,1)-Y(c,1)).^2;
RrR2(c,1)=(R(c,1)-Yp(1,1)).^2;
end

RrPp=1-(sum(RrPp1)/sum(RrPp2));
RrP=1-(sum(RrP1)/sum(RrP2));
RrL=1-(sum(RrL1)/sum(RrL2));
RrR=1-(sum(RrR1)/sum(RrR2));
Rrr=[RrL RrR RrP RrPp p];

s = ['Rrr',int2str(p),'=Rrr'];
eval(s);
name = ['Rrr' int2str(p), '.mat'];
eval(['save ', name]);

ErPp1=sum((Y-Pp).^2);
ErP1=sum((Y-P).^2);
ErL1=sum((Y-L).^2);
ErR1=sum((Y-R).^2);

Err=[ErPp1 ErP1 ErL1 ErR1 p];

s = ['Err',int2str(p),'=Err'];
eval(s);
name = ['Err' int2str(p), '.mat'];
eval(['save ', name]);

[nn,mm]=size(L);
X=1:n;

VbatLi=zeros(nn-1,1);VbatYi=zeros(nn-1,1);
VbatRi=zeros(nn-1,1); VbatPi=zeros(n-1,1); VbatPpi=zeros(n-1,1);
for jjj=1:nn-1
    VbatLi(jjj,1)=0.5*(L(jjj,1)+L(jjj+1,1)*3600);
    VbatRi(jjj,1)=0.5*(R(jjj,1)+R(jjj+1,1)*3600);
    VbatPi(jjj,1)=0.5*(P(jjj,1)+P(jjj+1,1)*3600);
    VbatPpi(jjj,1)=0.5*(Pp(jjj,1)+Pp(jjj+1,1)*3600);
    VbatYi(jjj,1)=0.5*(Y(jjj,1)+Y(jjj+1,1)*3600);
end

VbatPp1=sum(( VbatYi-VbatPpi).^2);
VbatP1=sum((VbatYi-VbatPi).^2);
VbatL1=sum((VbatYi-VbatLi).^2);
VbatR1=sum((VbatYi-VbatRi).^2);

ErrV=[VbatL1 VbatR1 VbatP1 VbatPp1 p];

s = ['ErrV',int2str(p),'=ErrV'];
eval(s);
name = ['ErrV' int2str(p), '.mat'];
eval(['save ', name])

```

```

[m n]=size(L);
X3=1:m;
h1 = figure;
format short
plot(X3,L,'b')
grid on
hold on
plot(X3,R,'c')
plot(X3,P,'m')
plot(X3,Pp,'k')
plot(X3,Y,'g')
ierr= max(X3)/2+0.05*max(X3);
imax=round(ierr);
imaxx=round(max(P));
kolp=Rrr(:,1);
ier= find(min(kolp) == kolp);

text(imax,imaxx,['R^2 pro přímku =',num2str(min(Rrr(:,1)))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(P)-3);

kolp=Rrr(:,2);
ier= find(min(kolp) == kolp);
text(imax,imaxx,['R^2 pro robustní přímku =',num2str(min(Rrr(:,2)))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(P)-6);

kolp=Rrr(:,3);
ier= find(min(kolp) == kolp);
text(imax,imaxx,['R^2 pro polynom 2° =',num2str(min(Rrr(:,3)))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
imaxx=round(max(P)-9);

kolp=Rrr(:,4);
ier= find(min(kolp) == kolp);
text(imax,imaxx,['R^2 pro polynom 3° =',num2str(min(Rrr(:,4)))],...
'VerticalAlignment','middle',...
'HorizontalAlignment','left',...
'FontSize',10)
title(['model 1.2 Batelov-Dvorce +',num2str(p-1),'hod'])
ylabel('průtok [m^3/s] ')
xlabel('doba trvání [hod]')

legend('LS','ROB','P2','P3','org data')
hold off
print -djpeg -r300

end

```

```

format short

ErrVc=vertcat(ErrV1,ErrV2,ErrV3,ErrV4,ErrV5,ErrV6,ErrV7,ErrV8,ErrV9,ErrV10;
    s = ['BErrVc',int2str(u),'=ErrVc'];
eval(s);
    name = ['BErrVc' int2str(u), '.mat'];
    eval(['save ', name]);
Errc=vertcat(Err1,Err2,Err3,Err4,Err5,Err6,Err7,Err8,Err9,Err10);
    s = ['BErrc',int2str(u),'=Errc'];
eval(s);
    name = ['BErrc' int2str(u), '.mat'];
    eval(['save ', name]);
RrrR=vertcat(Rrr1,Rrr2,Rrr3,Rrr4,Rrr5,Rrr6,Rrr7,Rrr8,Rrr9,Rrr10);

    s = ['BRrrR',int2str(u),'=RrrR'];
eval(s);
    name = ['BRrrR' int2str(u), '.mat'];
    eval(['save ', name]);

Xx=(1:cas)';

h3=figure;
format short e
plot(Xx,Errc(:,1),'b')
grid on
ylabel('chyba^2 [m^3/s]^2')
xlabel('doba doběhu [hod]')
hold on
plot(Xx,Errc(:,2),'c')
plot(Xx,Errc(:,3),'m')
plot(Xx,Errc(:,4),'k')
    imaxx=round(max(Errc));
imax=round(2);
kolp=Errc(:,1);
ier= find(min(kolp) == kolp);

text(imax(1,1),imaxx(1,1),['minimální chyba pro přímku
=',num2str(round(min(Errc(:,1)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
    imaxx=round(max(Errc)-max(Errc)*0.1);

kolp=Errc(:,2);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro robustní přímku
=',num2str(round(min(Errc(:,2)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
    imaxx=round(max(Errc)-max(Errc)*0.2);

kolp=Errc(:,3);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro polynom 2°
=',num2str(round(min(Errc(:,3)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...

```

```

        'HorizontalAlignment','left',...
        'FontSize',10)';
imaxx=round(max(Errc)-max(Errc)*0.3);

kolp=Errc(:,4);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro polynom 3°
=',num2str(round(min(Errc(:,4)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
title(['chyba^2 sumy okamžitých hodinových průtoků modelu 1.2 Batelov-
Dvorce '])
legend('LS','ROB','P2','P3')
hold off

h4=figure;

plot(Xx,ErrVc(:,1),'b')
grid on
ylabel('chyba objemu^2 [m^3]^2')
xlabel('doba doběhu [hod]')
hold on
plot(Xx,ErrVc(:,2),'c')
plot(Xx,ErrVc(:,3),'m')
plot(Xx,ErrVc(:,4),'k')
imaxx=round(max(ErrVc));
imax=round(2);
kolp=ErrVc(:,1);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro přímku
=',num2str(round(min(ErrVc(:,1)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
imaxx=round(max(ErrVc)-max(ErrVc)*0.1);

kolp=ErrVc(:,2);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro robustní přímku
=',num2str(round(min(ErrVc(:,2)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
imaxx=round(max(ErrVc)-max(ErrVc)*0.2);

kolp=ErrVc(:,3);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro polynom 2°
=',num2str(round(min(ErrVc(:,3)))), ' v čase h= ',num2str(min(ier)-1)],...
    'VerticalAlignment','middle',...
    'HorizontalAlignment','left',...
    'FontSize',10)
imaxx=round(max(ErrVc)-max(ErrVc)*0.3);

kolp=ErrVc(:,4);
ier= find(min(kolp) == kolp);
text(imax(1,1),imaxx(1,1),['minimální chyba pro polynom 3°
=',num2str(round(min(ErrVc(:,4)))), ' v čase h= ',num2str(min(ier)-1)],...

```

```

        'VerticalAlignment','middle',...
        'HorizontalAlignment','left',...
        'FontSize',10)
title(['chyba^2 objemu modelu 1.2 Batelov-Dvorce '])

legend('LS','ROB','P2','P3')


hold off
print -djpeg -r300

format short
end


```

## **PŘÍLOHA 3**

## MĚRNÝ PROFIL BATELOV




Obr. 71 Čáry překročení pro Johnsonovo rozdělení




Obr. 72 Rozdělení Johnsonovo

## MĚRNÝ PROFIL DVORCE




Obr. 73 Čáry překročení pro Johnsonovo rozdělení




Obr. 74 Rozdělení Johnsonovo



## MĚRNÝ PROFIL PTÁČOV



Obr. 75 Čáry překročení pro Johnsonovo rozdělení



Obr. 76 Rozdělení Johnsonov

## Hustoty pravděpodobnosti jednotlivých rozdělení

**Johnson:**

$$f(x) = \frac{1}{\sigma_\tau \sqrt{2\pi}} \cdot \frac{b-a}{(x-a) \cdot (b-x)} \exp \left\{ -\frac{1}{2\sigma_\tau^2} \left[ \ln \left( \frac{x-a}{b-x} \right) - m_\tau \right]^2 \right\} \quad (3)$$

$$\tau_i = \ln \left( \frac{x_i - a}{b - x_i} \right), \quad m_\tau = \frac{\sum_{i=1}^n \tau_i}{n}, \quad \sigma_\tau = \sqrt{\frac{\sum (\tau_i - m_\tau)^2}{n-1}} \quad (4)$$

**Charlier:**

$$f_z(z) = \varphi_0(z) - \frac{1}{3!} A_Y \varphi_0^{(3)}(z) + \varphi_0(z) - \frac{1}{4!} E_Y \varphi_0^{(4)}(z) \quad (5)$$

$$\frac{d^n \varphi_0(z)}{dz^n} = (-1)^n H_n(z) \varphi_0(z) \quad (6)$$

**Pearson III:**

$$f(x) = \frac{\alpha^{\alpha^2} \cdot e^{\frac{\alpha \mu(x)}{\sigma(x)} - \alpha^2}}{\Gamma(\alpha^2) \cdot \sigma^{\alpha^2}(x)} \cdot [\alpha \cdot \sigma(x) - \mu(x) + x]^{\alpha^2-1} \cdot e^{-\frac{\alpha}{\sigma(x)} \cdot x} \quad (7)$$

$$\alpha = \frac{2}{C_s(x)} \quad (8)$$

**Normální:**

$$f(x) = \frac{1}{\sigma_x \sqrt{2\pi}} \cdot e^{-\frac{1}{2} \left( \frac{x - \mu_x}{\sigma_x} \right)^2} \quad (9)$$

# **PROHLÁŠENÍ O SHODĚ LISTINNÉ A ELEKTRONICKÉ FORMY VŠKP**

## **Prohlášení:**

Prohlašuji, že elektronická forma odevzdané práce je shodná s odevzdanou listinnou formou.

V Brně dne 15.1.2013

.....  
podpis autora  
Tomáš Kozel